

Analýza a modelování příznaků kostních struktur z RTG a CT obrazových dat

Analýza a modelování příznaků kostních struktur z RTG a CT
obrazových dat

Bc. Tomáš Valášek

Diplomová práce

Vedoucí práce: Ing. Jan Kubíček, Ph.D

Ostrava, 2021

Abstrakt:

Tato diplomová práce pojednává o analýze a modelování příznaků kostních struktur z RTG a CT obrazových dat. Teoretická část představuje poznatky z rešerše odborných článků zabývajících se vznikem rentgenového záření, objasňuje princip rentgenu, CT a zobrazování kostí těmito metodami. Praktická část se zabývá výběrem vhodného algoritmu, včetně jeho nastavení, které umožní automatizovaně odlišit kost na RTG a CT snímku, vytvořením aplikace s uživatelským rozhraním, kde je tento algoritmus použit, a umožňuje analýzu a modelování kostních struktur. Kombinovaný algoritmus adaptivního prahování s využitím aktivních kontur se ukázal být jako nejpresnější algoritmus pro segmentaci kostí. Výsledná aplikace umožňuje snadné načítání různých obrazových formátů, listování soubory, automatické předzpracování obrazu, segmentaci, analýzu příznaků, nastavení citlivosti segmentace, ruční výběr oblasti zájmu a exportu všech výsledků do uživatelem zvoleného umístění. Tato aplikace byla použita pro analýzu náhodně vybraných 20 RTG a 20 CT snímků. Výsledkem je komparativní analýza srovnávaných příznaků kostní hustoty pro RTG a CT obrazová data.

Klíčová slova: Segmentace obrazu, adaptivní prahování, aktivní kontury, MATLAB

Abstract:

This diploma thesis disserts on the theme analysis and modelling of bone structure features from X-ray and CT images. The theoretical part presents a search from professional articles deal with formation X-rays. Explains the principle of X-ray. CT and image bones with these methods. Practical part deals with the selection of a suitable algorithm, including its settings which allows automatically distinguish bone on RTG and CT images. By creating application with user interface where this algorithm is used and allows analysis and modelling of bone structures. Combined algorithm adaptive thresholding using active contours proved to be the most accurate algorithm for bone segmentation. Final application allows easy loading of various images formats, browsing files, automatic image pre-processing, segmentation, symptom analysis, set the segmentation sensitivity, manually select an area of interest and export all results. This application was used for the analysis of X-ray and CT images. The result is a comparative analysis of bone density symptoms for X-ray and CT images.

Keywords: Image segmentation, adaptive thresholding, active contour, MATLAB

Poděkování

Rád bych vyjádřil poděkování vedoucímu mé diplomové práce, panu Ing. Janu Kubíčkovi, Ph.D., za jeho cenné rady a doporučení při konzultacích, které mi pomohly při řešení zejména v praktické části mé diplomové práce.

Obsah

Seznam použitých zkratk	7
Seznam obrázků	8
Seznam grafů	10
Seznam tabulek	10
Úvod	11
1 Rentgen a počítačová tomografie	12
1.1 Rentgenové záření	12
1.1.1 Vznik záření.....	12
1.2 Rentgenka	13
1.3 Interakce rentgenového záření s hmotou.....	14
1.4 Princip rentgenového zobrazovacího systému	15
1.4.1 Detekce intenzity RTG záření.....	16
1.4.2 Zobrazování kostí.....	17
1.5 Princip CT	20
1.5.1 Konstrukční řešení	21
1.5.2 Zobrazování kostí.....	23
2 Zpracování obrazových dat z RTG a CT	24
2.1 Obraz a reprezentace obrazových dat	24
2.2 Zpracování obrazu.....	25
3 Segmentační metody pro identifikaci kostí z CT a RTG obrazů	26
3.1 Detekce bodů, čar a hran.....	26
3.1.1 Výpočet diferencí.....	27
3.1.2 Detekce hranových bodů.....	28
3.1.3 Detekce hran.....	28
3.2 Prahování (thresholding)	31
3.3 Segmentace na základě detekce oblastí	32

3.4	Watersheds (přehrady)	33
3.5	Shlukování metodou k-středů (k-means).....	34
4	Shrnutí teoretické části	35
5	Praktická část	36
5.1	Datové soubory	36
5.1.1	Výběr snímků ze souboru RTG dat	36
5.1.2	Výběr snímků ze souboru CT dat	38
5.1.3	Tvorba zlatého standardu.....	40
5.1.4	Výběr vhodného algoritmu pro segmentaci.....	42
5.2	Algoritmus Otsu prahování	42
5.3	Algoritmus adaptivního prahování	43
5.4	Aktivní kontury.....	46
5.5	Algoritmus shlukování k-středů (k-means)	47
5.6	Výsledný počet testovacích kombinací	48
5.7	Srovnávací kritéria	48
5.7.1	Prostá podobnost oblastí.....	49
5.7.2	Jaccardovo kritérium podobnosti.....	49
5.7.3	Sørensen-Diceho kritérium podobnosti	49
5.7.4	Korelace	50
5.7.5	MSE – Mean Square Error	50
5.7.6	SSIM – Strukturální podobnost.....	50
5.8	Srovnávací skript	51
5.8.1	AlgorithmTest	51
5.8.2	Generování obrázků k jednotlivým algoritmům.....	52
5.8.3	Report k jednotlivým kritériím.....	56
6	Finální algoritmus	58
7	Grafické uživatelské rozhraní	59
7.1	Vzhled aplikace	59
7.2	Prvky v aplikaci.....	59
7.3	Postup při výběru dat.....	60

7.4	Nastavení segmentace	63
7.5	Načtení vybraných CT dat	63
7.6	Export dat.....	65
7.7	Formát exportovaných dat	67
7.8	Sensitivita	68
7.9	Optimalizace histogramu	69
7.10	Sledované parametry obrazu.....	71
7.10.1	Průměr (Mean)	71
7.10.2	Medián (Median)	71
7.10.3	Rozptyl (Variance).....	71
7.10.4	Směrodatná odchylka (Standard deviation)	71
7.10.5	Modus (Mode).....	72
7.10.6	Histogram	72
8	Komparativní analýza	73
8.1	Průměrná hodnota průměru.....	74
8.2	Průměrná hodnota mediánů.....	75
8.3	Průměrná hodnota rozptylů.....	76
8.4	Průměrná hodnota směrodatných odchylek	77
8.5	Průměrná hodnota modusů.....	78
8.6	Histogramy.....	79
9	Závěr	82
	Literatura	83
	Seznam příloh	86

Seznam použitých zkratk

CT Výpočetní tomografie

RTG Rentgen

RGB Barevný model

Seznam obrázků

Obrázek 1. Fyzikální princip rentgenky [4].....	14
Obrázek 2. Schematické znázornění rentgenu [5].	16
Obrázek 3. Konstrukční řešení detektoru s plochým panelem [7].....	17
Obrázek 4. Vyobrazení materiálů s různou hustotou na rentgenu [9]	17
Obrázek 5. Výsledný rentgenový snímek ruky [10].....	18
Obrázek 6. Segmentace kostí metodou AAM [14].....	19
Obrázek 7. Postupná zpětná projekce obrazu pomocí CT pod různými úhly [8].....	21
Obrázek 8. Výsledný obraz trupu pomocí CT – 2D a 3D zobrazení [8].....	22
Obrázek 9. Masky Prewittova a Sobelova operátoru [16]	29
Obrázek 10. Segmentace kostí prostřednictvím Cannyho detektoru [24].....	30
Obrázek 11. Výstupy adaptivního prahování při segmentaci kostí [24]	32
Obrázek 12. Segmentace kostí metodou Watersheds [24]	34
Obrázek 13. Dvacet vybraných RTG snímků: [zdroj vlastní].....	37
Obrázek 14. Dvacet vybraných CT snímků: [zdroj vlastní]	39
Obrázek 15. Deset vybraných RTG snímků použitých k nalezení vhodného algoritmu: [zdroj vlastní].....	40
Obrázek 16. Výsledek manuální anotace vybraných RTG snímků: [zdroj vlastní]	41
Obrázek 17. Histogram s 256 (vlevo) vs. 32 (vpravo) binů: [zdroj vlastní].....	43
Obrázek 18. Princip určování popředí/pozadí u jednotlivých pixelů: [zdroj vlastní]	45
Obrázek 19. Ukázka procesu zpracování. Zleva doprava: Původní obrázek, adaptivní prahování, po 50 iteracích aktivních kontur, po 100 iteracích aktivních kontur.: [zdroj vlastní].....	47
Obrázek 20. Znázornění výše uvedené struktury procesu srovnání segmentace: [zdroj vlastní]	51
Obrázek 21. Otsu prahování s počtem binů 16: [zdroj vlastní].....	52
Obrázek 22. Otsu prahování s počtem binů 96 a aktivními konturami 100 iterací: [zdroj vlastní]	53
Obrázek 23. Adaptivní prahování (lokální průměr): [zdroj vlastní].....	53
Obrázek 24. Adaptivní prahování (vážený průměr): [zdroj vlastní]	54
Obrázek 25. Adaptivní prahování (lokální průměr) + aktivní kontury 100 iterací: [zdroj vlastní]	54
Obrázek 26. Adaptivní prahování (vážený průměr) + aktivní kontury 100 iterací: [zdroj vlastní]	55

Obrázek 27. Shlukování (k-means) + aktivní kontury 100 iterací [zdroj vlastní]	55
Obrázek 28. Excel s výsledky prosté podobnosti oblastí (zeleně zvýrazněn nejlepší, červeně nejhorší algoritmus): [zdroj vlastní]	56
Obrázek 29. Aplikace po spuštění: [zdroj vlastní]	59
Obrázek 30. Zobrazení původního a segmentovaného: [zdroj vlastní]	60
Obrázek 31. Další prvky v aplikaci: [zdroj vlastní]	60
Obrázek 32. Kroky pro vybrání dat: [zdroj vlastní]	61
Obrázek 33. Nahraný vybraný obrázek společně s ostatními obrázky: [zdroj vlastní]	62
Obrázek 34. Zrušení výběru dat: [zdroj vlastní]	62
Obrázek 35. Import error: [zdroj vlastní]	63
Obrázek 36. Nastavení sensitivity a adjust contrast: [zdroj vlastní]	63
Obrázek 37. Segmentace CT snímků se špatnou identifikací kosti: [zdroj vlastní]	64
Obrázek 38. Použití oblasti zájmu: [zdroj vlastní]	64
Obrázek 39. Proces použití oblasti zájmu: [zdroj vlastní]	65
Obrázek 40. Ukázka exportu dat: [zdroj vlastní]	66
Obrázek 41. Úspěšný export dat: [zdroj vlastní]	66
Obrázek 42. Zrušení již vybraného exportu dat: [zdroj vlastní]	67
Obrázek 43. Export has been canceled: [zdroj vlastní]	67
Obrázek 44. Exportované data: [zdroj vlastní]	68
Obrázek 45. Ukázka obsahu pátého sloupce: [zdroj vlastní]	68
Obrázek 46. Ukázka nastavených odlišných sensitivit: [zdroj vlastní]	68
Obrázek 47. Srovnání kumulativní distribuční funkce jasu: [zdroj vlastní]	69
Obrázek 48. Původní histogram: [zdroj vlastní]	70
Obrázek 49. Optimalizovaný histogram: [zdroj vlastní]	70
Obrázek 50. Hodnoty průměru v jednotlivých RTG/CT snímcích: [zdroj vlastní]	74
Obrázek 51. Hodnoty mediánu v jednotlivých RTG/CT snímcích: [zdroj vlastní]	75
Obrázek 52. Hodnoty rozptylu v jednotlivých RTG/CT snímcích: [zdroj vlastní]	76
Obrázek 53. Hodnoty směrodatné odchylky v jednotlivých RTG/CT snímcích: [zdroj vlastní] ...	77
Obrázek 54. Hodnoty modusů v jednotlivých RTG/CT snímcích: [zdroj vlastní]	78
Obrázek 55. Nahoře histogram RTG ruky, dole histogram CT kloubu: [zdroj vlastní]	79
Obrázek 56. Nahoře histogram RTG nohy, dole histogram CT LHK: [zdroj vlastní]	80
Obrázek 57. Nahoře histogram RTG prstů rukou, dole histogram CT LDK: [zdroj vlastní]	81

Seznam grafů

Graf 1. Průměrná hodnota průměrů CT/RTG snímků: [zdroj vlastní]	74
Graf 2. Srovnání průměrných hodnot mediánu RTG/CT snímků: [zdroj vlastní]	75
Graf 3. Srovnání průměrných rozptylů RTG/CT snímků: [zdroj vlastní]	76
Graf 4. Srovnání průměrných směrodatných odchylek RTG/CT snímků: [zdroj vlastní]	77
Graf 5. Srovnání průměrných modusů RTG/CT snímků: [zdroj vlastní]	78

Seznam tabulek

Tabulka 1. Popis algoritmu a celkový počet nastavení: [zdroj vlastní]	48
Tabulka 2. Nejlepší výsledky pro jednotlivá srovnávací kritéria: [zdroj vlastní]	58

Úvod

Lékařský obor je pro lidstvo velmi důležitý – díky medicíně se lidem postupně prodlužuje život, neumírají tolik na nemoci, které dnes lze běžně léčit, či na nemoci, které dříve dokázaly vyhladit celé oblasti; také jsme schopni lépe napravovat různá zranění, kdy může být narušena měkká tkáň, ale také kupříkladu tkáň pojivová (kosti). Za tento pokrok vděčíme neustálému výzkumu a analýze získaných poznatků. Ke svému rozvoji však medicína potřebuje co nejkvalitnější lékařské přístroje – terapeutické, diagnostické, ale také zobrazovací systémy.

K moderním zobrazovacím systémům lze jednoznačně zařadit počítačový tomograf (CT); rentgen (RTG) je sice o poznání starší, ale stále velmi hojně využívaný (byť byl především z hlediska konstrukčního, ale také z hlediska způsobu zobrazení snímků značně modernizován). Podrobnější informace o obou přístrojích a o možnostech zpracování jejich dat přinese tato diplomová práce, která se věnuje analýze a modelování příznaků kostních struktur zobrazených pomocí počítačového tomografu či rentgenu.

Zásadní otázkou tedy je, proč je modelování hustoty kostí a jejich identifikace tak důležitá? Zdaleka se totiž nejedná pouze o diagnostiku zlomenin a jejich následnou nápravu; v ortopedii může rentgen sloužit také k včasnému rozpoznání revmatoidní artritidy, kdy jsou jedním z projevů této nemoci například otoky na kloubech, které jsou poškozovány chronickým zánětem, což se zejména v pozdějším stadiu prokáže i na RTG snímku [1].

V teoretické části práce jsou nejprve uvedeny způsoby vzniku rentgenového záření a jeho interakce s hmotou (tkání pacienta), také jsou představeny obě technologie (CT a RTG), včetně uvedení základních principů zobrazování kostí (kapitola 1). Následuje rešerše segmentačních metod pro identifikaci kostních struktur ze získaných obrazových dat (kapitola 3). K tomu je nezbytné uvést také pojmy z oblasti zpracování obrazu (kapitola 2). Stěžejním zdrojem pro diplomovou práci je zejména zahraniční anglicky psaná odborná literatura.

V praktické části této diplomové práce se nachází tvorba aplikace v prostředí MATLAB, která zahrnuje implementaci algoritmu, jehož výběr byl proveden porovnáním s ostatními typy algoritmů, a to na základě srovnávacích kritérií, která jsou velmi detailně popsána. Poté následuje popis vybraného algoritmu adaptivního prahování společně s aktivními konturami a jeho finální implementace do vytvořené aplikace. V té byly poté segmentovány RTG a CT snímky kostí a vypočítány sledované parametry, na základě kterých bylo možné v závěru práce provést komparativní analýzu.

1 Rentgen a počítačová tomografie

Objev rentgenového záření (tzv. paprsky X), které je základem obou přístrojů, se datuje již do 19. století. První rentgenový snímek vznikl při experimentech v roce 1895 a v roce 1972 bylo do medicínské praxe úspěšně uvedeno první CT [3].

První kapitola si klade za cíl objasnit vznik rentgenového záření, které využívají ke své činnosti oba přístroje (RTG i CT), a také uvést způsoby interakce záření s materiálem. Dále bude ozřejměn princip, na němž jsou přístroje založeny, a u každého budou uvedeny způsoby, jakými lze pomocí rentgenu i počítačového tomografu zobrazovat kosti.

1.1 Rentgenové záření

Rentgenové záření představuje elektromagnetické vlny s velmi krátkou vlnovou délkou – od 0,006 nm do 1,25 nm a s energií v rozmezí od 1 do 500 keV. Zdrojem záření je rentgenka, která bude popsána v kapitole 1.1.2. Vznik rentgenového záření souvisí se dvěma procesy – jednak se změnou rychlosti nabitých částic (elektronů) a dále se změnou energetických hladin elektronů [4]. Rentgenové záření je schopno projít jakoukoliv hmotou, a protože je ionizující, dokáže způsobit nevratné poškození tkání [5].

1.1.1 Vznik záření

V prvním případě se jedná o tzv. **brzdné rentgenové záření** vznikající interakcí elektronů s těžkými jádry. Pokud se elektron dostane do blízkosti jádra, začne jej ovlivňovat jeho magnetické pole, čímž je elektron vychýlen ze své dráhy, která se zakříví a elektron zpomalí, až může zastavit úplně. Při zabrzdění ztratí část kinetické energie, která se přemění na fotony rentgenového záření. Jeho vlnová délka je určena množstvím ztracené kinetické energie – více ztracené kinetické energie znamená kratší vlny. Proto se také ve spektru vyskytují fotony o různých vlnových délkách, čímž vznikne spojité spektrum [4][5].

Daný jev lze vyjádřit následující rovnicí, kdy na levé straně je energie elektronu, která se musí rovnat energii fotonu na straně pravé [5]:

$$e \cdot U = h \cdot f \quad (1)$$

kde e je náboj elektronu, U je urychlovací napětí rentgenky, h je Planckova konstanta a f je frekvence záření, které lze tedy vyjádřit jako [5]:

$$f = \frac{e \cdot U}{h} \quad (2)$$

Dále je známá rovnice pro vlnovou délku rentgenových paprsků λ_{min} [5]:

$$\lambda_{min} = \frac{c}{f} = \frac{h \cdot c}{e \cdot U} \quad (3)$$

V případě změny energetických hladin elektronů se hovoří o tzv. **charakteristickém rentgenovém záření**. Elektrony jsou v atomech vázány v elektronových obalech. Čím dál od jádra jsou, tím je jejich energie menší. Pokud mají elektrony dopadající na anodu rentgenky dostatečně velkou energii (větší, než je vazebná energie elektronu v obalu), vyrazí elektrony z vnitřní slupky elektronového obalu, čímž se atom dostane do ionizovaného stavu a stane se nestabilním. Vzniklé díry se zaplní elektrony z vyšších energetických hladin (dál od jádra); při jejich přechodu vzniká energie, která je vyzářena coby fotony rentgenového záření. Rozdíl energetických hladin určuje charakteristickou frekvenci záření – liší se podle použitého materiálu anody rentgenky, která bude popsána v následujícím textu. Spektrum je tvořeno čarami [4][5].

1.2 Rentgenka


Fyzikální princip rentgenky je naznačen na obr. 1. Rentgenka je skleněná vakuová trubice obsahující katodovou sestavu (katodu – žhavenou spirálu, emitör, zdroj proudu) a anodu, které jsou umístěny proti sobě a jsou vyrobeny převážně z wolframu (s příměsí některého dalšího prvku). Elektrony vysílané z emitöru mohou být vlivem katody zrychleny až na 65 % rychlosti světla [4]. Po připojení napětí v řádu až stovek kV začnou z katody vystřelovat elektrony směrem k anodě, avšak pouze asi 1 % z nich se podílí na vzniku rentgenového záření, účinnost je tedy velmi malá. Většina kinetické energie se tedy přemění na teplo (až 2 500 °C), a proto je nutné rentgenku chladit – buď vzduchem, nebo olejem [5][6].

Z konstrukčního hlediska existují tři typy rentgenek [4]:

1. s pevnou anodou – má tvar terčíku,
2. s rotační anodou – má tvar talíře,
3. rentgenky, které se otáčejí celé.

Rentgenky s pevnou (stacionární) anodou se v současné době používají především u dentálních rentgenů, mnohem častěji se používají rentgenky s rotační anodou. Anoda se může otáčet rychlostí až 20 000 otáček za minutu, dnes se používají RTM (rhenium-wolfram-molybden) anody. Tento typ anody lze více tepelně zatížit, jelikož se během expozice pohybuje a má větší dopadovou plochu [5][6].

Celootáčivá rentgenka kombinuje výhody obou předchozích. Díky nepohyblivé anodě může být trvale chlazena a zároveň rotuje (byť s celou trubicí), čímž se lépe rozloží vznikající teplo. Proto je možné generovat rentgenové paprsky s vysokým výkonem [4].



Obrázek 1. Fyzikální princip rentgenky [4].

1.3 Interakce rentgenového záření s hmotou

Díky velmi krátkým vlnám a vysokým energetickým hladinám je rentgenové záření schopno snadno prostupovat hmotou (to, jak moc, závisí i na vlastnostech hmoty). Část primárního paprsku je při interakci s atomy dané hmoty absorbována, což umožňuje vytvářet výsledné obrazy tkání v těle [4]. V RTG zobrazovacích systémech je měřena intenzita rentgenového záření / zeslabeného po průchodu hmotou [3]:

$$I = I_0 \cdot e^{-\mu d} \quad (4)$$

Zde je I_0 primární intenzita dopadajícího rentgenového záření, μ je koeficient zeslabení a d tloušťka absorbující hmoty. Útlum hmoty P lze vyjádřit rovnicí [3]:

$$P = \ln \frac{I_0}{I} = \mu \cdot d \quad (5)$$

Z rovnice vyplývá, že útlum hmoty je definován jako přirozený logaritmus poměru primární intenzity I_0 k zeslabené intenzitě I , což lze vyjádřit také jako součin tloušťky d a koeficientu zeslabení μ . Hodnota měřené intenzity I exponenciálně klesá s rostoucí tloušťkou hmoty d [3].

Jak již bylo řečeno, při průchodu rentgenových paprsků hmotou dochází k jejich zeslabení. To lze obecně vysvětlit čtyřmi efekty [4]:

1. fotoelektrickým jevem,
2. koherentním (Rayleighovým nebo Thomsonovým) rozptylem,
3. nekoherentním (Comptonovým) rozptylem,
4. tvorbou iontových párů.

Vznik iontových párů lze v diagnostické radiologii zanedbat, jelikož aby mohl vzniknout pár elektron-pozitron, musel by foton mít energii minimálně 1,02 MeV. Proto lze vzít v úvahu první tři jevy a zahrnout je do výpočtu koeficientu zeslabení μ [4]:


$$\mu = \mu_{foto} + \mu_{koh} + \mu_{nekoh} \quad (6)$$

kdy každý ze tří efektů se podílí svým útlumem na celkovém koeficientu zeslabení. Značnou měrou jej ovlivňuje **fotoelektrický jev**, při němž foton vyrazí z některé z vnitřních slupek obalu elektron s energií, která odpovídá rozdílu mezi energií RTG záření a vazebnou energií elektronu. Vzniká tím charakteristické záření s diskretním spektrem (viz kapitola 1.1.1). Čím má prvek vyšší atomové číslo Z, tím větší je vazebná energie a tím větší rozdíl v energiích nastane. Současně má vliv i energie rentgenového záření – k jevu častěji dochází, pokud má záření nižší energii, a tedy kratší délku vlny [4]. Na absorpční koeficient μ_{foto} má významný vliv především hustota hmoty, která je záření vystavena [5].

Čím větší energii rentgenové záření má, tím více se začne projevovat **Comptonův (nekoherentní) rozptyl**. Foton záření při srážce s elektronem materiálu mu jednak předá část energie a jednak elektron vychýlí ze své původní dráhy, přičemž vzniká sekundární foton, jehož dráha je také odchýlena od dráhy původního primárního fotonu. Energie sekundárního fotonu je ve srovnání s primárním fotonem nižší; rozptyl sekundárních fotonů je možný mezi 0 až 180° [5]. **Koherentní (Rayleighův) rozptyl** nepřispívá k přenosu energie záření. Foton interaguje s celým atomem, má příliš malou energii na to, aby dokázal dostat elektron do vyšší energetické hladiny. Tento typ rozptylu je v konvenční radiologii většinou zanedbatelný [4].

1.4 Princip rentgenového zobrazovacího systému

Princip rentgenového přístroje je naznačen na obr. 2. Zde je PC primární clona, A, B jsou místa, kde dochází k rozptylu záření a SC je sekundární clona. Z napevno umístěné rentgenky (anoda může být pevná nebo rotační) je generováno rentgenové záření, z něhož je nejprve odfiltrována část spektra obsahující příliš dlouhé vlny, což by byla pro pacienta zbytečná zátěž. Primární clona má za úkol dostatečně zúžit svazek vysílaného záření, sekundární clona zachycuje již záření, které vzniklo vzájemným působením rentgenového záření a tkání vyšetřovaného člověka. Pod sekundární clonou se nachází kazeta s filmem [5].




Obrázek 2. Schematické znázornění rentgenu [5].

1.4.1 Detekce intenzity RTG záření

K detekci procházejícího rentgenového záření lze využít chemické energie, kdy se použije rentgenový film, jehož fotografická emulze obsahuje halogenidy stříbra, které jsou aktivovány rychlými elektrony. Vznikne tím tzv. latentní obraz, jehož vyvolání pak probíhá jako u klasického fotofilmu. Míra zčernání závisí na množství záření, které prošlo ozařovanou hmotou, což je indikováno množstvím aktivovaných stříbrných zrnků. Čím jemnější zrnka jsou, tím je obraz ostřejší. Další možností může být polovodičový detektor, který se používá ve skiografii [4][5][6].


V moderní digitální radiografii je rentgenový paprsek vzorkován z hlediska prostoru a intenzity v pixelech. Mezi nejčastěji používané systémy patří systémy obsahující detektory s plochým panelem (FPD). V nich je použita TFT matice, která obsahuje tenké TFT (Thin Film Transistor) tranzistory, díky čemuž lze vytvořit detektor s plochým panelem. Jednomu pixelu odpovídá jeden TFT tranzistor. Celá soustava je vykreslena na obrázku 3, kdy vrstvu A tvoří převodník (ze světlocitlivého materiálu), vrstva B obsahuje TFT matici a C představuje skleněný substrát [7][8].



Obrázek 3. Konstrukční řešení detektoru s plochým panelem [7].

1.4.2 Zobrazování kostí

Rozdílná absorpce při průchodu hmotou určuje výslednou sytost ve stupních šedi. Více je RTG záření absorbováno hustším prostředím s větší tloušťkou a s vyšším protonovým číslem. Pokud jde o tkáně v těle – zde mají nejvyšší protonové číslo kosti, které obsahují vápník a fosfor, proto mají na výsledném obraze velmi světlý odstín [5]. Srovnání je na obr. 4, kde je uveden výsledný odstín pěti materiálů – vzduchu, tuku, měkkých částí, kostí a kovů. Z toho je také zřejmé, proč mají kovy na výsledném rentgenovém snímku rušivý efekt – pohlcují velkou část rentgenového záření, které již dál nepronikne.



Obrázek 4. Vyobrazení materiálů s různou hustotou na rentgenu [9]

Faktor D vyjadřuje množství pohlcené dávky v [Gy] a měří se v jednotkách Gray = J/kg. Pro různé tkáně bude mít různou hodnotu. Například pro tuk bude výrazně nižší než pro kosti, které mají větší schopnost záření absorbovat, tím pádem mají větší útlum [4][6]. Výsledný rentgenový snímek ruky je na obrázku 5.



Obrázek 5. Výsledný rentgenový snímek ruky [10]

Kromě klasických rentgenových snímků (ať už analogových nebo digitálních) lze rentgenové záření využít i v tzv. **kostní denzitometrii**. Vlivem osteoporózy dochází ke snížení hustoty kostí, resp. hustoty minerálů v kostech (BMD – Bone Mineral Density), které se stávají náchylnějšími ke zlomeninám. U žen je riziko vzniku osteoporózy větší, nejčastěji dochází ke zlomeninám páteře, kyčle nebo předloktí; riziko navíc stoupá po menopauze, jelikož se snižuje hladina estrogeneru.

Měření pomocí metody DXA (dual-energy x-ray absorptiometry) patří k nejpoužívanějším zejména díky vysoké přesnosti a krátkému času expozice. Prostřednictvím DXA je možno měřit hustotu minerálů páteře a kyčle. V principu se jedná o měření přenosu záření skrze dvě různé energetické hladiny fotonů. Jak již bylo uvedeno v kapitole 1.3, koeficient útluhu je závislý na protonovém čísle a energii rentgenového záření. Pokud tedy bude měřena intenzita záření, které prošlo tkání, na dvou energetických hladinách, umožní to stanovit plošnou hustotu dvou typů tkáně (v případě DXA se jedná o kostní minerál a měkkou tkáň) [11].

Metody segmentace kostí z obrazových dat lze obecně rozdělit do několika kategorií [12]:

1. Metody založené na prahování (kapitola 3.2)
2. Metody založené na detekci bodů a hran (kapitola 3.1)
3. Algoritmy založené na oblastech: detekce oblastí, watersheds, shlukování (kapitoly 3.3., 3.4 a 3.5)
4. Grafické metody
5. Klasifikační metody
6. Numerické modely


První tři metody budou popsány dále v kapitole 3. Základem grafické metody je identifikace hran z grafu, ve kterém každý pixel odpovídá uzlu a určité sousední pixely jsou spojeny do hran. Váhy na každé hraně měří odlišnost mezi pixely (tzv. vážený graf) a na základě toho jsou jednotlivé pixely přiřazovány do sub-grafů [13]. Metoda je podobná shlukování (clusteringu).

Do klasifikačních metod lze zařadit neuronové sítě. Jednotlivé segmenty jsou klasifikovány s ohledem na odlišnosti (resp. podobnosti) bodů v jasu, textuře, kontinuitě křivek a podobně. Zmínit lze například Fuzzy neuronové sítě či neuronovou síť typu backpropagation (se zpětným šířením chyby). Ve druhém případě je nutné síť nejprve na segmentaci (rozpoznávání) kostí naučit, což se provádí manuálně [12].

Co se týče numerických modelů, těch existuje celá řada. Za nejdůležitější lze považovat Snake Model (Active Contour Model), Level Set a Active Shape/Appearance Model. **Model aktivních kontur** (snakes – hadi) se uplatňuje u CT a RTG obrazů zejména pokud jsou zašuměné. Uvnitř obrazu se zavede křivka, která je postupně deformována. Na její deformaci mají vliv obrazové síly – vnitřní a vnější. Vnitřní obrazové síly kontrolují hladkost, zatímco vnější síly přitahují hada k výrazným obrazovým prvkům (čáry, hrany). Algoritmem je had postupně iterativně deformován, až je nalezena taková konfigurace, která dokáže hada co nejlépe přizpůsobit kontuře objektu. Nevýhodou je zejména nutnost manuální inicializace hada.

Model tzv. **Level Set** segmentace je založen na podobném principu. Používaná level set funkce je vlastně vícedimenzionální funkce a přiřazuje každému bodu v rovině (x, y) výšku nad nulovou hladinou, která odpovídá hranici segmentovaného objektu. Také v tomto případě je nutná počáteční manuální inicializace, své uplatnění mají zejména v případě segmentace složitějších obrazů.

Dalšími dvěma modely jsou **Active Appearance Model (AAM)** a **Active Shape Model (ASM)**. Lze je použít pouze za předpokladu, že je k dispozici dostatek trénovacích dat, ze kterých se vytvoří model segmentovaných objektů za pomoci PCA analýzy (statistická metoda). Výhodou těchto modelů oproti výše zmíněným metodám level set a modelu aktivních kontur je, že tvar obrysů je možno deformovat více předvídatelným (kontrolovatelným) způsobem. Nevýhodou je bezesporu nutnost mít k dispozici dostatečně velkou sadu trénovacích dat [12]. Výstup AAM segmentace je na obrázku č. 6.



Obrázek 6. Segmentace kostí metodou AAM [14]

1.5 Princip CT


Rentgenové přístroje jsou schopny vyobrazovat scénu pouze dvourozměrně, navíc dlouhou dobu platilo, že výstup byl pouze analogový. Mimo jiné i proto byl vyvinut počítačový tomograf, který je schopný dodat digitální obrazy. Dnes se však digitalizace dostala i do klasické radiografie (kapitola 1.4.1). CT využívá rovněž rentgenového záření, avšak na odlišném principu. K jeho pochopení je možno si představit lidské tělo jako soubor nekonečně mnoha diskrétních řezů o určitém elementárním objemu, a ty jsou snímány a následně výpočetně rekonstruovány [3][4].

Pro elementární objem se používá označení voxel – má tři rozměry: x, y, z. Detektorem počítačového tomografu se měří intenzita záření prošlého tkání (resp. útlum záření) stejným způsobem, jaký byl popsán v kapitole 1.3 pouze s tím rozdílem, že navíc bylo zavedeno ještě CT číslo udávané v HU (Hounsfieldova jednotka). Je to kvůli tomu, že velikost koeficientu zeslabení se odvíjí také od energie rentgenového záření. Pokud by se tedy změnila energie RTG záření, změnil by se i výsledný obraz. CT číslo se počítá jako [3]:

$$CT = \frac{\mu_T - \mu_{voda}}{\mu_{voda}} \cdot 1\,000\,HU \quad (7)$$

Kde μ_T odpovídá útlumu tkáně.

Pro rekonstrukci obrazu je potřeba vypočítat sumu koeficientů zeslabení tkáně pro každý bod. A k tomu je nutné, aby záření prošlo každým bodem vícekrát (změní se úhel). Pro jeden voxel se hodnota útlumu zjistí za pomoci Fourierovy transformace [5]. Výsledný obrazový bod je šedotónový (256 hodnot). Na obrázku 7 je vykreslená postupná filtrovaná zpětná projekce obrazu v různých úhlech. Postupně jsou zde uvedeny obrázky s 2n filtrovanými zpětnými projekcemi, přičemž n postupně nabývá hodnot od 0 do 8 (tedy od 1 do 1 024) [8].



Obrázek 7. Postupná zpětná projekce obrazu pomocí CT pod různými úhly [8]

1.5.1 Konstrukční řešení

Konstrukčně CT odpovídá soustavě rentgenky a detektoru, přičemž celá tato soustava se pohybuje, ačkoliv existují i systémy, kde jsou detektory napevno umístěny a pohybují se pouze rentgenky [5]. CT se postupně vyvíjelo – nejprve se snímací soustava otáčela po kruhových drahách, později začala opisovat spirálovou dráhu (tzv. single-slice spiral CT) s jednou řadou detektorů. Postupně počet těchto spirál narůstal a narůstal i počet řezů, které bylo najednou možno provést (multi-slice CT) současně se snižující se možnou tloušťkou řezu. Existují tomografy schopné snímat současně až 320 řezů s 320 řadami detektorů [3]. Na obrázku 8 je CT snímek trupu: tloušťka jednoho řezu je pouze 0,5 mm (proto je obraz dostatečně ostrý), napravo je dvourozměrný obrázek, nalevo vyrenderovaný 3D obraz.



Obrázek 8. Výsledný obraz trupu pomocí CT – 2D a 3D zobrazení [8]

Základními součástmi CT tedy jsou [4]:

1. Systém pro manipulaci s pacientem včetně stolu
2. Gantry – tunel, kam je pacient postupně posouván, zde je prováděno ozařování pacienta a sběr dat
3. Řídící jednotka – obsluhuje ji operátor
4. Počítače
5. Chladicí systém

Gantry má svou pevnou a rotující část; v rotující části se nacházejí [4]:

1. Soustava ke generování rentgenového záření – rentgenky, kolimátory tvarující svazek RTG záření, vysokonapěťový generátor (až 140 kV)
2. Soustava generující data: detektory, systém přenosu dat
3. Napájecí prvky

Z rotující části postupuje signál do části pevné (stacionární), kde se nacházejí různé ovládací prvky k chladicímu systému, k posunu pacienta a podobně, a následně jsou data odeslána do počítače, aby bylo možno obraz rekonstruovat [4].

Detektory se používají buď scintilační nebo plynové. Plynové detektory jsou řešeny jako vysokotlaká komora plněná xenonem, scintilační detektory jsou tvořeny krystaly (např. wolfram kadmia) [3].

1.5.2 Zobrazování kostí

CT se používá pro diagnostiku srdeční funkce, k vyšetření stavu plic a tlustého střeva, ale lze pomocí něj zobrazovat také kosti, přičemž jeho trojrozměrné zobrazení poskytuje detailnější informace o stavu kostí ve srovnání s konvenčním radiografickým snímkem [4]. Lze tak odhalit nejenom potenciální zlomeniny, ale také onemocnění kostí včetně rakoviny [11].

Stejně jako pro zobrazování kostí pomocí rentgenu se uplatňuje i v počítačové tomografii fakt, že vápník má vysoké protonové číslo a tím pádem vysokou schopnost absorpce rentgenového záření. Proto vykazují kosti velký útlum, a zatímco například vzduch vykazuje hodnoty CT - 1 000 HU, tuk okolo - 90 HU a krev do 60 HU, hodnota v případě kostí je běžně až ke 2 000 HU. CT číslo pro kosti je však velmi silně závislé na energii záření a lze jej zvýšit snížením napěťové úrovně [3].

Také CT nalézá uplatnění v kostní denzitometrii, jeho výhodou je navíc trojrozměrné zobrazení hustoty kostí – metoda se nazývá QCT. Pomocí ní se měří vnitřní tkáň kostí (kostní dřeň). Měřit lze na jakémkoliv tomografu, pokud je vybaven externím referenčním fantomem, aby bylo možno překalibrovat CT číslo na hodnoty odpovídající kostem. Největší nevýhodou tak zůstává cena [15].

2 Zpracování obrazových dat z RTG a CT

Tato část bude věnována obrazu – nejprve bude definován obraz i s ohledem na specifika obrazových dat získaných pomocí RTG a CT. Navazovat budou podkapitoly popisující možnosti předzpracování obrazu a také segmentace kostí. Existuje celá řada metod k segmentaci obrazu, ty nejčastěji používané uvede navazující kapitola 3.

2.1 Obraz a reprezentace obrazových dat

Obraz lze definovat jako 2D funkci $f(x, y)$, kde x a y jsou prostorové souřadnice a hodnota funkce f může vyjadřovat obecně různé informace o dané dvojici souřadnic – například barvu, ale také intenzitu obrazu (gray level, grayscale – stupně šedi). Souřadnice mohou být buď spojité nebo diskrétní; u spojitých existuje vždy mezi dvěma libovolnými souřadnicemi nekonečně mnoho dalších souřadnic. K digitálnímu zpracování obrazu (pomocí počítače) je však potřeba takový digitální obraz, který má diskrétní jak souřadnice, tak i hodnotu funkce f , což znamená, že počet souřadnic bude konečný stejně jako hodnota intenzity obrazu v daném bodě [16].

Obraz je rozdělen do pravidelné a konečné mřížky, jejíž velikost je zpravidla dána vlastnostmi senzoru (v případě např. fotoaparátu), nebo také konstrukčním řešením přístrojů, jako jsou RTG a CT (jejich rozlišovací schopností). Jeden bod v mřížce se nazývá obrazový element neboli pixel. Každý pixel má tedy konkrétní umístění a hodnotu.

Obecně lze v digitálním obraze zvolit RGB model (červená, zelená, modrá), ale existují i další (CMYK, YUV apod.) [17]. Pro CT a RTG je však typické použití stupňů šedi, a proto bude dále uvažován pouze tento model [16]. Neméně důležitá je také kvantizace. Teoreticky si lze představit nekonečně mnoho stupňů šedi, proto bylo nutné stanovit určité normy a rozdělit možné hodnoty do kvant. Nejobvyklejší je reprezentace osmibitová, kdy každý bod může být vyjádřen jednou hodnotou z 256 možných, používá se však také stupnice 16bitová, která dává na výběr ze 65 535 hodnot.

K ukládání obrazových dat lze použít různé obrazové formáty. Často se jedná o 8bitové formáty (například JPEG), pro profesionální práci však najdou využití spíše formáty 16bitové (TIFF, PNG a další), jejichž výsledná velikost je sice obrovská ve srovnání s 8bitovými formáty, ale zůstane zachováno více detailů [17].

Pro lékařské účely existuje speciální formát DICOM. Kromě samotných obrazových dat obsahuje také detaily o použitém zařízení (RTG, CT atd.), o druhu a účelu vyšetření, dále také popis snímku odborníkem a informace o pacientovi. Standardem pro ukládání obrazu může být JPEG či RLE a dodatečné informace jsou zaznamenány formou určitých značek. Nejedná se však pouze o standard pro ukládání dat, ale také o standard popisující komunikaci mezi zařízeními, takže lékaři mohou zpracovávat snímky ze zařízení různých výrobců pomocí jednotného rozhraní [18].

2.2 Zpracování obrazu

Zpracování obrazu velmi úzce souvisí s oblastí počítačového vidění potažmo umělé inteligence, přičemž nelze jednoznačně říct, který typ úlohy spadá ještě pod zpracování obrazu a který už ne. Existují tři úrovně zpracování obrazu: nízká, střední a vysoká [16].

Nízkoúrovňové zpracování

Sem lze zařadit vcelku jednoduché operace vedoucí k potlačení šumu, zlepšení kontrastu či jasů. Vstupem i výstupem z této úrovně jsou obrazy, proto lze hovořit také o předzpracování obrazu. Zejména filtrace šumu je pro přístroje, jako je rentgen či počítačový tomograf, důležitá – šum mohou způsobit např. pohyby pacienta (expoziční doba je k tomu dostatečně dlouhá) [16].

Ve stručnosti lze zmínit některé metody z této oblasti. Pokud jde o filtraci šumu – nejjednodušším způsobem je průměrování (k tomu slouží konvoluce s danou maskou), filtrovat lze také mediánem. Ke zlepšení ostroty slouží pro změnu hranové detektory (Sobelův operátor, Laplacián, Cannyho detektor a další) [19].

Středněúrovňové zpracování

Sem spadá například segmentace, která slouží k rozčlenění obrazu do určitých oblastí či objektů; ale také popis těchto oblastí umožňující jejich identifikaci. Je možné oblast charakterizovat číselným či nečíselným vyjádřením tak, aby bylo možné jednoznačně určit například tvar oblasti. Vstupem této úrovně jsou obrazy, výstup však již tvoří jednotlivé atributy definující objekty v obraze (hrana, jas, textura a podobně), tedy množina bodů nebo čar, které je ohraničují. Výsledek může sloužit přímo k diagnostice – např. díky lepší viditelnosti patologických jevů na kostech či tkáních, případně může být vstupem do další fáze [16]. Podrobnosti budou uvedeny v dalším textu.

Vysokoúrovňové zpracování

Poslední fází je samotné porozumění obrazu. K tomu je nutné objekty v obraze identifikovat, což znamená, že obrazová data jsou přiřazena do některé třídy na základě svých vlastností či příznaků. Využít lze s výhodou metody umělé inteligence, počítačového vidění či statistické metody [16].

Analytické zpracování rentgenových a CT snímků se používá např. k detekci karcinomů, stáří kostí (např. pro účely soudní patologie, archeologie nebo endokrinologie) atd. [20].

3 Segmentační metody pro identifikaci kostí z CT a RTG obrazů

Segmentace patří mezi nejnáročnější úlohy zpracování obrazu. Hlavním úkolem segmentace je rozdělit obraz na části, které korespondují s objekty či oblastmi, které mají představovat části reálného světa (tráva, obloha, alfanumerické znaky a podobně), přičemž obraz lze rozsegmentovat buď úplně, nebo částečně.

Úplná segmentace rozdělí obraz do oblastí odpovídajících přímo objektům v obraze, k čemuž se využívají metody z vyšších úrovní zpracování obrazu. V případě některých segmentačních úloh to však není nezbytné, zejména pokud se jedná o obraz, na jehož pozadí se nacházejí určité kontrastní objekty (např. krevní buňky).

Částečná segmentace obraz rozděljuje na oblasti, které neodpovídají objektům; výsledkem je rozčlenění na oblasti se stejnými předem definovanými vlastnostmi (např. jas či barva). Výstup částečné segmentace lze použít jako vstup pro zpracování obrazu na vyšší úrovni [21].

Přesnost, s jakou je obraz rozsegmentován, je stěžejní pro další postupy z vyšší úrovně zpracování, potažmo pro identifikaci objektů a porozumění obrazu. Při segmentaci lze vycházet ze dvou základních předpokladů:

- V místech, kde se náhle změní hodnota intenzity, se nachází hrana.
- V jedné oblasti by se měly nacházet obrazové body mající podobné vlastnosti na základě určité definované sady pravidel.

Existují metody, které pracují s jedním nebo druhým předpokladem; lepších výsledků je však dosaženo kombinací obou přístupů. Algoritmy je možné rozdělit do několika skupin [16]:

1. Detekce bodů, čar a hran
2. Prahování
3. Detekce oblastí
4. Watersheds
5. Shlukování (metodou k-průměrů)

3.1 Detekce bodů, čar a hran

O hranových detektorech již byla zmínka v kapitole 2.2 v souvislosti s potlačením šumu. Hranové detektory jsou založeny na detekci gradientu v obraze, to znamená, že zjišťují místa, kde dochází k náhlým změnám v jasu (např. mezi okrajem kosti a okolní tkání). Hranové detektory lze rozdělit následovně [22]:

1. Operátory (Robertsův, Sobelův, Kirschův)

2. Transformace (Fourierova, Laplaceova)
3. Další (Cannyho detektor, detektor Marra-Hildreth)

3.1.1 Výpočet diferencí

Společným rysem všech těchto algoritmů je využití vlastností první či druhé derivace k nalezení extrémů. Musí platit několik základních principů pro numerickou derivaci, kdy je určena aproximace derivace funkce intenzity v daném bodě [16]:

1. Aproximace první i druhé derivace musí být nulová v místech s konstantní intenzitou
2. Aproximace první i druhé derivace musí být nenulová tam, kde se hodnota intenzity mění
3. Aproximace první derivace musí být nenulová v bodech v těsné blízkosti změn intenzity, avšak pro druhou derivaci musí být v těchto bodech nulová

V případě digitálního obrazu (kdy obrazová funkce není spojitá, nýbrž diskrétní) se místo derivací počítají difference. V případě jednorozměrné funkce $f(x)$ lze diferenci definovat následovně [16]:

$$\frac{\partial f}{\partial x} = f(x + 1) - f(x) \quad (8)$$

Člen $\partial f / \partial x$ popisuje změnu úrovně jasu ve směru osy x . Jelikož obrazová funkce $f(x, y)$ je dvourozměrná, budou počítány parciální derivace ve směru dvou os. Pro obrazový bod (x, y) tedy platí následující diferenční vzorce [23]:

$$\frac{\partial f(x, y)}{\partial x} = f(x + 1, y) - f(x, y) \quad (9)$$

$$\frac{\partial f(x, y)}{\partial y} = f(x, y + 1) - f(x, y) \quad (10)$$

Člen $\partial f(x, y) / \partial x$ popisuje změnu úrovně jasu ve směru osy x ; $\partial f(x, y) / \partial y$ představuje změnu úrovně jasu ve směru osy y .

Pro druhou derivaci platí [23]:

$$\frac{\partial^2 f(x, y)}{\partial x^2} = f(x - 1, y) - 2f(x, y) + f(x + 1, y) \quad (11)$$

$$\frac{\partial^2 f(x, y)}{\partial y^2} = f(x, y - 1) - 2f(x, y) + f(x, y + 1) \quad (12)$$

Tyto vztahy byly získány derivací vzorců (9) a (10).

3.1.2 Detekce hranových bodů

K detekci izolovaného bodu hrany lze použít Laplacián. Nejprve je nutno stanovit diskrétní derivaci druhého řádu a následně sestavit filtrační masku, která je na ní založená. Jako filtrační masky se používají izotropní filtry, které jsou nezávislé na rotaci obrazu. A právě nejjednodušším příkladem tohoto postupu je Laplacián ∇^2 , který lze pro obrazovou funkci $f(x, y)$ definovat následovně [16]:

$$\nabla^2 f = \frac{\partial^2 f(x, y)}{\partial x^2} + \frac{\partial^2 f(x, y)}{\partial y^2} \quad (13)$$

Přičemž $\partial^2 f(x, y)/\partial x^2$ a $\partial^2 f(x, y)/\partial y^2$ jsou diskrétní derivace druhého řádu a (x, y) jsou souřadnice obrazového bodu. Aby mohla být vypočítána konvoluce, musí se na daný bod aplikovat filtrační maska tvaru čtverce o velikosti např. 3×3 , která nerotuje. Proto je možné zjistit pouze velikost hrany, nikoliv její směr. Laplacián může být vhodný také pro detekci čar [16][19].

3.1.3 Detekce hran

Detekce hran sestává ze tří základních kroků:

Potlačení šumu – hranové detektory jsou na šum velmi citlivé

Detekce hranových bodů – jsou vybrány body, které mohou být hranové

Detekce hran (jejich umístění) – z množiny potenciálně hranových bodů jsou vybrány pouze body, které jsou skutečně součástí hrany

V případě hranových detektorů lze určit velikost gradientu $\text{mag}(\nabla f(x, y))$, který bude odpovídat délce hrany [16]:

$$\text{mag}(\nabla f(x, y)) = \sqrt{\left(\frac{\partial f(x, y)}{\partial x}\right)^2 + \left(\frac{\partial f(x, y)}{\partial y}\right)^2} \quad (14)$$

Směr gradientu je dán úhlem α [16]:

$$\alpha(x, y) = \tan^{-1}\left(\frac{\partial f(x, y)}{\partial y} / \frac{\partial f(x, y)}{\partial x}\right) \quad (15)$$

kde $f(x, y)$ je obrazová funkce a $\partial f(x, y)/\partial x$ a $\partial f(x, y)/\partial y$ jsou jednotlivé parciální derivace pro každý pixel v obraze; tyto parciální derivace popisují změnu úrovně jasu ve směru os x a y .

Jedním z prvních detektorů, který používá dvourozměrnou masku, je **Robertsův** operátor. Masku je rotující o velikosti 2×2 , což není dostačující. Proto byly později navrženy další operátory – **Prewittův**, **Sobelův**, **Kirschův**, které používají masku o velikosti 3×3 . Rozdíl v maskách je v použitých číslech uvnitř – viz obrázek 9.

-1	-1	-1	-1	0	1
0	0	0	-1	0	1
1	1	1	-1	0	1

Prewitt


-1	2	-1	-1	0	1
0	0	0	-2	0	2
1	2	1	-1	0	1

Sobel

Obrázek 9. Masky Prewittova a Sobelova operátoru [16]

Maska Prewittova operátoru je jednodušší na implementaci, avšak rozdíl mezi oběma maskami z výpočetního hlediska není příliš velký. Sobelův operátor je díky použité masce odolnější vůči šumu, jelikož jej lépe vyhlazuje, což je velká výhoda. Další možnosti poskytuje kombinace použití gradientních metod s prahováním.

Existují však i složitější algoritmy – například **Cannyho** detektor či operátor **Marra-Hildreth** – které jsou u pokročilejších aplikací využívány častěji. Principem je rozpoznávání hran za předpokladu, že druhá derivace prochází nulou. Spojení takto detekovaných hranových bodů vytváří špagetový efekt (viz obr. 10).



Obrázek 10. Segmentace kostí prostřednictvím Cannyho detektoru [24]

Postup při detekci hran algoritmem Marra-Hildreth je následující: Původní obraz prochází Gaussovským filtrem typu dolní propust, pro jehož výstup je vypočítán Laplaceán – lze použít masku o velikosti 3×3 . Napříč takto získaným obrazem se hledají nulové hodnoty. Lze tedy říct, že výstupem je konvoluce původního obrazu a LoG filtru (Laplacian of a Gaussian).

Dvourozměrnou Gaussovu funkci $G(x, y)$ lze definovat jako [16]:

$$G(x, y) = e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (16)$$

Kde (x, y) určuje polohu obrazového bodu v obou osách a σ je směrodatná odchylka. K nalezení výrazu pro LoG je potřeba nalézt následující difference [16]:

$$\nabla^2 G(x, y) = \frac{\partial^2 G(x, y)}{\partial x^2} + \frac{\partial^2 G(x, y)}{\partial y^2} \quad (17)$$

Po úpravách lze stanovit výraz pro LoG jako [16]:

$$\nabla^2 G(x, y) = \left[\frac{x^2 + y^2 - 2\sigma^2}{\sigma^4} \right] e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (18)$$

Operátor ∇^2 představuje Laplaceán a $G(x, y)$ je již zmiňovaná Gaussova funkce.

Algoritmus, který využívá Cannyho detektor, je přeci jen odlišný: opět se sice použije Gaussovský filtr k vyhlazení obrazu, ale následně jsou počítány velikosti a směry gradientu. Gaussovská čtvercová konvoluční maska může být o libovolné velikosti. A jelikož se kolem lokálních maxim velikosti gradientu objevují široké hřebeny, které nejsou maximy, je v dalším kroku nutné je potlačit. K samotné detekci hran se použije dvojité prahování – nízký a vysoký práh, aby se vyloučily falešně pozitivní a falešně negativní hrany. Proto by skutečné hrany měly

být detekovány, a naopak domnělé hrany, které hranami nejsou, by měly být potlačeny. Posledním krokem je již pouze analýza propojení bodů do hran [16].


Další možnosti poskytují detektory využívající některou z transformací – například Houghovu transformaci či Fourierovu transformaci. Houghova transformace se využívá u detekce hranic na úrovni globálního zpracování [16][22].

3.2 Prahování (thresholding)

Základním předpokladem pro prahování (thresholding) je fakt, že různé objekty v obraze mají různé vlastnosti. V případě segmentace kostí lze tedy uvažovat fakt, že kosti mají vyšší schopnost absorpce rentgenového záření, a proto jim v šedotónovém obraze přísluší světlejší odstín. Prahování je jednou z nejstarších metod používaných pro analýzu RTG a CT obrazových dat. Princip je prostý – pro obraz je možné manuálně stanovit práh, a všechny body obrazu, které jsou jasnější, mají nastaven jas na maximální hodnotu (bílá barva, bod objektu) a všem ostatním bodům bude hodnota jasu nastavena na nulu (černá barva, bod pozadí). Obrovská výhoda spočívá v jednoduchosti implementace. Volba hodnoty prahu může být ponechána na výzkumníkovi, ale lze ji automatizovat také s použitím histogramu.

Hodnota prahu však nemusí být nutně neměnná, lze ji posouvat na základě vlastností okolních bodů; taková metoda bývá nazývána jako adaptivní prahování. Výstup takové metody je k nahlédnutí na obrázku č. 11. Na obrázcích a až c jsou v rámečcích naznačeny chybně vysegmentované části.

Metodu lze rovněž vylepšit o použití více prahů – vícenásobné prahování. Dvojité prahování využívá například Cannyho detektor, použití více než dvou prahů se v praxi pro svou náročnost nepoužívá. Prahování není na šum náchylné, přídavný Gaussovský šum může dokonce výsledný obraz zpřesnit.



Obrázek 11. Výstupy adaptivního prahování při segmentaci kostí [24]

Princip základního globálního prahování spočívá v experimentálním stanovení hodnoty prahu, která rozdělí obraz na dvě části. Pro každou část se spočítá průměrná hodnota intenzity pixelů a vypočítá se nový práh dle vzorce [16]:

$$T = 0,5 * (m_1 + m_2) \quad (19)$$

Kde m_1 a m_2 jsou průměrné intenzity obou částí. Celý postup se opakuje, dokud rozdíl mezi dvěma po sobě jdoucími hodnotami T nebude menší než předdefinovaná hodnota parametru ΔT .

Jednoduché prahovací metody lze optimalizovat dostatečným rozptylem mezi segmentovanými třídami z hlediska hodnot intenzit jednotlivých pixelů. Dobře zvolený práh je takový, který poskytuje co nejlepší oddělení tříd z hlediska hodnot těchto intenzit. Tento požadavek splňuje algoritmus Otsu, kromě toho pracuje s výpočty na úrovni histogramu obrazu (celkový součet, průměr a výpočet rozptylu mezi třídami), který lze získat velmi snadno.

V dosavadním textu kapitoly byla brána v úvahu jediná proměnná – hodnota intenzity bodu na stupnici šedi. Zvláštním případem je prahování více proměnných, kdy lze prahy stanovovat pro více obrazových informací – typické použití je pro barevné obrazy, kdy má svůj práh stanovena každá z barev (RGB) [16].

3.3 Segmentace na základě detekce oblastí

Výše popsané metody využívají buď výpočty gradientu jasu (velikost a směr) nebo jeho distribuci vyobrazenou histogramem. Existují však metody, které hledají jednotlivé segmenty

tím, že do nich postupně přidávají body odpovídající předem definovanému parametru. Obvykle je jím podobnost, kdy se očekává jas z přibližně stejného rozsahu.

Algoritmy pro detekci oblastí mohou být implementovány buď za pomoci uživatele, nebo bez něj – uživatel může před zpracováním definovat známé body (pro potřeby této diplomové práce za něj lze považovat bod na kosti) a algoritmem jsou dopočítány okraje kosti, ale mohou být také plně automatické a dané oblasti nalezne algoritmus sám. Algoritmy pro detekci oblastí jsou rozděleny do dvou skupin [16]:

1. Metoda růstu oblastí
2. Dělení a slučování oblastí


V prvním případě je cílem sdružovat pixely a shluky pixelů do větších oblastí, které mají přesně definovaná kritéria pro růst. Na začátku je uvažován pouze shluk bodů, se kterými jsou postupně další body srovnávány, a na základě podobnosti se k nim přidávají. V podstatě je potřeba vyřešit dva problémy – počáteční definici shluku bodů a pravidlo, kterým se další růst oblasti zastaví [16][22].

Druhá metoda (dělení a slučování oblastí) pracuje s obrazem rozděleným na nesouvislé části. Následně jsou jednotlivé oblasti sloučeny nebo dále rozděleny na základě segmentačních pravidel [16].

3.4 Watersheds (přehrad)

Tři výše zmíněné metody mají oproti výhodě v rychlosti implementace a výpočtu také několik nevýhod – kromě citlivosti na šum je zásadní problém v tom, že zdaleka ne vždy ohraničí správně celý segment, či naopak vyprodukují segmentů příliš mnoho. Metoda Watersheds (přehrad) je postavena na analogii se záplavami – jas obrazu je použit jako výšková mapa hypotetické krajiny, kdy nejjasnější body jsou ty nejvýše položené – hory; nejméně jasné body jsou naopak nejnižší se nacházející údolí.

Takto vytvořená virtuální krajina je následně zaplavena do určité výšky, a to tak, aby se voda nepřelévala mezi jednotlivými údolími. Výsledkem simulace používající algoritmus Watersheds jsou opět segmenty, které jsou však na rozdíl od dosud popsanych metod uzavřené. Pro problematiku detekce kostí to znamená, že například v okrajích kostí nebudou segmentované otvory [16][25]. Na obrázku č. 12 je výstup segmentace (c).



Obrázek 12. Segmentace kostí metodou Watersheds [24]

Algoritmus Watersheds lze použít také pro účely segmentace obrazových dat z lékařských přístrojů. Metoda je vcelku rychlá a intuitivní a lze s ní rozsegmentovat i obraz s nízkou úrovní kontrastu bez nutnosti jej před segmentací upravovat. Mezi nevýhody patří riziko nadbytečné segmentace obrazu [26].

3.5 Shlukování metodou k-středů (k-means)

Jednou z nejmodernějších metod, která našla své uplatnění, je metoda shlukování metodou k-středů (K-means clustering). Algoritmus vychází z předpokladu, že na začátku není jasné, jaké objekty se v obraze mají nacházet, a probíhá automaticky bez nutnosti zásahu uživatele v procesu inicializace. Oboje lze považovat v procesu segmentace za výhodu.

V principu je obraz nejprve rozdělen do co nejmenšího počtu skupin, shluků, clusterů. Algoritmus postupnou iterací nachází řešení problému, což znamená, že dále seskupuje, případně rozděljuje clusterů do K-clusterů na základě jejich podobnosti [27]. Dlužno podotknout, že tam, kde algoritmus Watersheds nevykazuje dostatečnou přesnost (detekuje více segmentovaných objektů v obraze ve srovnání s realitou), lze aplikovat algoritmus K-means. Tyto algoritmy jsou zkoumány i v součinnosti s ostatními algoritmy (např. Watersheds nebo Cannyho hranovým detektorem) a dovolují efektivněji segmentovat např. snímky z CT a z magnetické rezonance [26].

4 Shrnutí teoretické části

Práce byla věnována teoretickým základům z oblasti rentgenu a počítačové tomografie a řešerši segmentačních metod pro detekci kostí v obraze. V první kapitole byl popsán vznik rentgenového záření, které je základem obou zmiňovaných přístrojů. Rozdíl mezi nimi je v konstrukčním řešení, kdy rentgen obsahuje jednu soustavu rentgenka-detektor, zatímco počítačový tomograf těchto soustav obsahuje nepoměrně více (přesný počet je závislý na konkrétním typu CT). Detektor zaznamenává intenzitu rentgenového záření, které pacientem prošlo.

Vyšetřovat kosti lze jak přes RTG, tak přes CT. Zatímco rentgen poskytuje dvourozměrnou informaci o kosti, CT snímá trojrozměrně, proto je možné zkoumat vnitřní tkáň kostí, což u rentgenu není možné. Kostí lze výborně zobrazovat proto, že pohlcují rentgenové záření více než okolní tkáň – rušivým elementem tak zůstávají kovové předměty.

Jak ukázala navazující kapitola 3, specifikum obrazů získaných pomocí RTG a CT spočívá v tom, že jsou zpravidla v odstínech šedi, proto je pixel o souřadnicích (x, y) reprezentován pouze jedinou numerickou hodnotou – intenzitou šedi. S obrazem je možné pracovat na různých úrovních, od nízké až po vysokou. Segmentace se nachází uprostřed a charakterizuje ji fakt, že jejím vstupem je obraz, avšak výstup je již tvořen vlastnostmi, které umožňují rozlišovat objekty v obraze.

V dalším textu byly jednotlivé segmentační metody popsány podrobněji od základních hranových detektorů přes metody prahování až k pokročilejším algoritmům, jako je třeba Watersheds nebo shlukování. Hranové detektory pracují s velikostí a směrem gradientu jasu a obraz je konvulován s příslušnou konvoluční maskou. Naproti tomu Watersheds nebo shlukování jsou iterační metody, kde je segmentace postupně zpřesňována na základě porovnání určitého bodu s již existujícím shlukem bodů, který má předem definované vlastnosti a zkoumá se jejich podobnost.

Nevýhodou hranových detektorů je jejich velká citlivost na šum, v případě prahování je zase nutné vhodně zvolit práh, ačkoliv existují i metody, které práh určují automaticky z histogramu. Také některé pokročilé metody mají svá úskalí – například algoritmus Watersheds má tendence obraz „nadsegmentovat“, tedy rozdělit na více částí, než by měl.

5 Praktická část

Praktická část této diplomové práce spočívala nejprve ve výběru vhodných dat, které byly využity k nalezení vhodného algoritmu a statické analýze. Skrze šest porovnávacích kritérií byl vybrán vhodný algoritmus, který byl následně implementován do výsledné aplikace. Jako vývojové prostředí bylo zvoleno prostředí MATLAB, což je prostředí pro technické výpočty, které umožňuje širokou paletu zpracování dat, včetně jednoduché tvorby GUI. V aplikaci byly následně vypočítány statistiky a sledované parametry z provedených segmentací. Které byly použity pro finální komparativní analýzu.

5.1 Datové soubory

Pro tuto práci byly vybrány dva rozsáhlé datové soubory z různých zdrojů. Jeden s RTG snímky, druhý se snímky z CT. Nejprve byly všechny snímky prohlédnuty a následně vybrány snímky k segmentaci. Pro analýzu segmentačních algoritmů bylo vybráno 10 RTG snímků různých kostí. CT snímky byly nevhodné pro testování segmentace, protože si byly velice podobné. Poté bylo vybráno 20 odlišných RTG snímků a 20 CT snímků pro statickou analýzu kostí.

5.1.1 Výběr snímků ze souboru RTG dat

Soubor dat s RTG snímky obsahoval zhruba 300 snímků různých kostí. Byla provedena selekce snímků a mezi vybraná data byly zařazeny snímky těchto kostí: holeně, hrudníku, chodidla, kolena, nohy, nohy zepředu, paty, paže, prstů nohou, prstů rukou, předloktí a celé ruky. Snímky jsou v různé kvalitě, různého rozlišení a různého obrazového formátu (PNG, JPG).



Obrázek 13. Dvacet vybraných RTG snímků: [zdroj vlastní]


5.1.2 Výběr snímků ze souboru CT dat

Soubor CT dat obsahoval zhruba 400 snímků, avšak pouze tři různé typy. Snímky byly rozděleny do sad, každá sada obsahovala snímek kosti a následně snímky řezů této kosti. Jednalo se o snímky kloubů, horních a dolních končetin. Všechny snímky byly ve formátu DICOM.

Z důvodu velké podobnosti snímků byly vybrány pouze 3 typy kostí:

1. Snímek levé dolní končetiny a její řezy
2. Snímek kloubu a jeho řezy
3. Snímek levé horní končetiny a její řezy

Vzhledem k ochraně osobních údajů bylo nutné odstranit popisy na snímcích, které snímky obsahovaly. Toto odstranění bylo realizováno ve volně dostupném programu MicroDicom, společně s tímto odstraněním bylo také provedeno převedení z DICOM na obrazový formát PNG. Všechny použité snímky jsou tedy ve formátu PNG. Rozlišení CT snímků je rovněž různé.



Obrázek 14. Dvacet vybraných CT snímků: [zdroj vlastní]


5.1.3 Tvorba zlatého standardu

Zlatý standard je manuální anotace snímků, která slouží k následnému porovnání kvality segmentace. V tomto případě spočívá tvorba zlatého standardu v manuální anotaci 10 vybraných RTG snímků.

To znamená, že ke všem 10 vybraným RTG snímkům byla v programu Zoner Photo Studio X vytvořena binární maska. Toho bylo docíleno ručním vybarvením kostí na snímcích bílou barvou, zbytek snímku byl vyplněn černou barvou. Snímky tak obsahovaly pouze hodnoty 0 a 255. Výsledkem tedy je binární maska, která se bude porovnávat se segmentací vybraných algoritmů.



Obrázek 15. Deset vybraných RTG snímků použitých k nalezení vhodného algoritmu: [zdroj vlastní]



Obrázek 16. Výsledek manuální anotace vybraných RTG snímků: [zdroj vlastní]

5.1.4 Výběr vhodného algoritmu pro segmentaci

Jedním ze stěžejních bodů této diplomové práce bylo nazelení vhodného segmentačního algoritmu, který se následně použije v GUI aplikaci. MATLAB má široký výběr segmentačních metod, proto bylo potřeba oddělit ty, které lze plně automatizovat a nepotřebují manuální anotaci (vstup od uživatele, který zpomaloval segmentaci a činil ji nezáživnou).

Do vhodných kandidátů na výsledný algoritmus bylo vybráno 8 postupů:

1. Otsu prahování (s variabilním nastavením)
2. Adaptivní prahování (lokální průměr)
3. Adaptivní prahování (vážený průměr)
4. Adaptivní prahování (lokální průměr) + aktivní kontury
5. Adaptivní prahování (vážený průměr) + aktivní kontury
6. Otsu prahování + aktivní kontury
7. Shlukování + aktivní kontury

5.2 Algoritmus Otsu prahování

Metoda Otsu slouží k automatickému prahování obrázků v odstínech šedi. Tento algoritmus se snaží rozdělit pixely na dvě třídy pixelů (pozadí a popředí) tak, aby minimalizoval rozptyl uvnitř tříd pixelů [28].

Tento rozptyl pixelů definujeme takto:

$$\sigma_{\omega}^2(t) = \omega_1(t)\sigma_1^2(t) + \omega_2(t)\sigma_2^2(t) \quad (20)$$

Váhy ω_i jsou pravděpodobnosti dvou tříd rozdělených do dvou tříd prahem t a σ_i^2 je rozptyl v dané třídě. Hledaný práh t je takový, který má maximální hodnotu σ_{ω}^2 .

Je dokázáno, že minimalizace rozptylu uvnitř třídy je ekvivalentní k maximalizaci rozptylu mezi třídami.

$$\sigma_b^2(t) = \sigma^2 - \sigma_{\omega}^2(t) = \omega_1(t)\omega_2(t)[\mu_1(t) - \mu_2(t)]^2 \quad (21)$$

Kde μ_i je střední hodnota střídny.

Pravděpodobnost třídy $\omega_1(t)$ je vypočítána z histogramu:

$$\omega_1(t) = \sum_0^t p(i) \quad (22)$$

Střední hodnota třídy $\mu_1(t)$ je:

$$\mu_1(t) = \left[\sum_0^t p(i) x(i) \right] / \omega_1 \quad (23)$$


Kde $x(i)$ je hodnota i -té přihrádky v histogramu. Analogicky lze spočítat $\omega_2(t)$ a $\mu_2(t)$ i pro část histogramu větší než t .

V praxi se používá častěji algoritmus maximalizace rozptylu mezi třídami, jelikož je výpočetně méně náročnější než ekvivalentní postup minimalizace uvnitř tříd.

V tomto případě bylo rozhodnuto metodě Otsu nastavit různý počet binů. Počtem binů se rozumí, do jakého počtu sloupců (kategorií) se rozdělí histogram (viz obrázek 18.). Kdy každý sloupec může nabývat stejné šířky a z takto rozdělených histogramů se poté automaticky spočítá vhodný práh pomocí maximalizace rozptylu mezi popředím a pozadím.

Algoritmus Otsu se tedy testoval s odlišným, náhodně vybraným počtem binů. Celkový počet takto testovaných nastavení je 16. Konkrétně byly histogramy rozděleny do těchto počtů binů: 16, 32, 48, 64, 80, 96, 112, 128, 144, 160, 176, 192, 208, 224, 240, 256.

Nejlepší výsledek vykazoval Otsu algoritmus při dělení na 96 binů. Proto byl vybrán k dalšímu testování s aktivními konturami pouze v tomto nastavení.



Obrázek 17. Histogram s 256 (vlevo) vs. 32 (vpravo) binů: [zdroj vlastní]

5.3 Algoritmus adaptivního prahování

Adaptivní prahování se od klasického prahování liší tím, že nepoužívá pro každý pixel stejnou hodnotu prahu, ale určuje ji pro jednotlivé části obrazu dynamicky. Prozkoumávání menších oblastí je výhodnější z důvodu, že je v nich větší pravděpodobnost menších jasových rozdílů. Menší oblasti jsou tedy výhodnější z hlediska prahování.


V praxi se používá vícero různých adaptivní algoritmů. Nejčastěji se uplatňuje Bradleyho algoritmus [29], který se dá popsat takto:

1. Vytvoří se klouzavé vyhledávací okno přizpůsobené velikosti vstupního obrazu
2. Okno se pohybuje po obraze a zkoumá pixel po pixelu včetně jeho okolí
3. Sečtou se všechny pixely ve vyhledávacím okně

4. Suma pixelů ve vyhledávacím okně se vynásobí koeficientem citlivosti
5. Vybere se vždy pixel uprostřed vyhledávacího okna a vynásobí se celkovým počtem pixelů ve vyhledávacím okně
6. Porovnají se tyto dvě hodnoty
7. Pokud je suma větší, zkoumaný pixel je pixel popředí, jinak pixel pozadí

Implementace adaptivního prahování v MATLABu má několik odlišností od Bradleyho algoritmu, tak jak je autor popsal ve své práci [29]. Neporovnává se přímo suma pixelů z vyhledávacího okna, ale počítá se reprezentativní hodnota vyhledávacího okna, která se porovná s hodnotou prahovaného pixelu.

MATLAB nabízí několik způsobů, jak vypočítat tuto reprezentativní hodnotu. Kvůli smysluplné délce této práce byly do textu zahrnuty pouze dvě nastavení – Local mean (dále lokální průměr) a Gauss statistic (dále vážený průměr). Tato nastavení vykazovala nejlepší výsledky a byla výpočetně nejrychlejší. V prvním případě se jedná o výchozí nastavení, kdy se stanovuje prostý lokální průměr hodnot pixelů uvnitř vyhledávacího okna. V druhém případě se jedná o vážený lokální průměr uvnitř vyhledávacího okna, kdy jsou váhy stanoveny Gaussovou funkcí, která má střed uprostřed prahovacího okna. Grafickou prezentaci prahování můžeme vidět na Obrázek 18, který znázorňuje postup algoritmu.



Obrázek 18. Princip určování popředí/pozadí u jednotlivých pixelů: [zdroj vlastní]

$$c = x \cdot y \quad (24)$$

$$V = c \cdot v_{m,n} \quad (25)$$

$$S_{v_{i,j}} = \sum_{i=1, j=1}^{x,y} v_{i,j} \quad (26)$$

$$T_{v_{i,j}} = S_{v_{i,j}} \cdot s \quad (27)$$

Když $V \leq T$ tak $v_{m,n} \rightarrow$ pixel pozadí, jinak $v_{m,n} \rightarrow$ pixel popředí

Kdy $x \cdot y$ je horizontální/vertikální velikost klouzavého okna v pixelech, c je celková velikost klouzavého okna a je dána vztahem $c = 2 \cdot \text{floor}([x; y] \div 16) + 1$

$v_{m,n}$ je analyzovaný pixel, V je objem jasu v klouzavém okně, m je horizontální střed klouzavého okna, n je vertikální střed klouzavého okna, $S_{v_{i,j}}$ je suma jasu okolo pixelu $v_{m,n}$. Dále pak $T_{v_{i,j}}$ je adaptivní práh jasu pro pixel $v_{m,n}$ a s je sensitivita.

5.4 Aktivní kontury

Aktivní kontury jsou iterativní metodou, při které se snažíme v každé iteraci vytvarovat křivku (konturu) tak, aby se přiblížila hranám obrazce, které se snažíme v obrazových datech detekovat. Aktivní kontura je sama osobě uzavřenou křivkou, která se deformuje pomocí vnějších a vnitřních sil.

Vnější síly se snaží přiblížit konturu ve směru detekované hrany, vnější síly naopak brání této deformaci. Obě tyto síly jsou stanovovány v každé iteraci z obrazových dat. Cílem iterace je vybrat takovou křivku, která má nejnižší energii. Deformace probíhá ve směru klesajícího gradientu (ve směru minimální energie).

Kdy výpočet těchto energií můžeme vyjádřit pomocí těchto vzorců.

$$E_{snake} = E_{internal}(v(s)) + E_{image}(v(s)) + E_{con}(v(s)) \quad (28)$$

$$E_{internal} = E_{cont} + E_{curv} \quad (29)$$

$$E_{image} = w_{line}E_{line} + w_{edge}E_{edge} + w_{term}E_{term} \quad (30)$$

Kde:

$v(s)$ – je křivka aktivní kontury

$E_{internal}$ – je vnitřní energie kontury

E_{image} – je vnější energie obrazových dat

E_{con} – je energie omezení, zde rovno 0

E_{cont} – je energie spojitosti kontury

E_{curv} – je energie hladkosti kontury

E_{line} – je energie linií v obraze

E_{edge} – je energie hran v obraze


E_{term} – je energie okrajů v obraze

w_{line} – je váha linií

w_{edge} – je váha hran

w_{term} – je váha okrajů

U aktivních kontur je obecně potřeba určit počáteční pozici a tvar křivky, dále pak počet iterací. Počáteční pozice a tvar křivky se vytvoří s pomocí segmentace vybraným algoritmem. Aktivním konturám se následně předá výsledek segmentace. U testovaných algoritmů jsem volil počet iterací vždy: 20, 40, 60, 80, 100, 120, 140, 160, 180, 200.



Obrázek 19. Ukázka procesu zpracování. Zleva doprava: Původní obrázek, adaptivní prahování, po 50 iteracích aktivních kontur, po 100 iteracích aktivních kontur.: [zdroj vlastní]

Nastínění principu fungování spojení prahování a aktivních kontur můžeme vidět na Obrázek 19. Ukázka procesu zpracování. Zleva doprava: Původní obrázek, adaptivní prahování, po 50 iteracích aktivních kontur, po 100 iteracích aktivních kontur. Nejdříve je vybrán RTG snímek, poté je provedena segmentace, která je označena žlutou barvou. Následně je výsledek segmentace předán aktivním konturám a ty ho dotvarují – modrá barva.

5.5 Algoritmus shlukování k-středů (k-means)

Další vybraný testovací algoritmus je algoritmus shlukování (k-means). Tento algoritmus je citlivý na počáteční nastavení, protože počáteční nastavení (těžiště) se volí náhodně. Z tohoto důvodu je dobré provést opakovaný přepočítání těžiště. Opakované získání stejného výsledku zvyšuje pravděpodobnost správného výsledku.

Postup shlukování je následující:

1. Nastaví se dva shluky (pro pixely popředí a pozadí)
2. Vygeneruje se náhodné počáteční těžiště
3. K těžišti se přiřadí nejbližší pixel a těžiště se přepočítá
4. Přepočítání se provádí po každém přidání, přičemž se provádí, dokud nejsou přiřazeny všechny pixely k jednomu ze shluků
5. Přepočítání končí konvergencí – pokud 2x po sobě jdoucím přepočítáním nedojde

k přeskupení pixelu z jednoho shluku do druhého

6. Algoritmus se opakuje od bodu 2, maximálně však 8krát. Tento počet je čistě specifický pro tuto práci.

5.6 Výsledný počet testovacích kombinací

Vzhledem k obohacení algoritmů o aktivní kontury výsledný počet činí 58 kombinací. Počet kombinací u jednotlivých algoritmů můžete vidět v Tabulka 1.

Název testovaného algoritmu	Počet kombinací
Adaptivní prahování (vážený průměr)	1
Adaptivní prahování (lokální průměr)	1
Adaptivní prahování (lokální průměr) + aktivní kontury	10
Adaptivní prahování (vážený průměr) + aktivní kontury	10
Otsu prahování (s variabilním nastavením)	16
Otsu prahování + aktivní kontury	10
Shlukování (k-means) + aktivní kontury	10
Celkový počet testovacích nastavení	58

Tabulka 1. Popis algoritmu a celkový počet nastavení: [zdroj vlastní]

5.7 Srovnávací kritéria

Pro objektivní a kvantitativní porovnání dostupných algoritmů pro segmentaci je potřeba použít exaktní kritéria, která tento účel naplní. Pro srovnání jednotlivých algoritmů a výběr toho nejlepšího bylo bráno v úvahu celkem šest různých kritérií, jejichž popis je uveden níže.

Jejich účel je vždy stejný – porovnat zlatý standard, tj. ručně vytvořenou binární masku a algoritmem vytvořenou segmentační masku a poskytnout jasnou kvantitativní odpověď, jak moc jsou si vstupní obrazová data podobná.

Vybraná kritéria byly následující:

1. Prostá podobnost oblastí
2. Jaccardovo kritérium podobnosti
3. Sørensen-Diceho kritérium podobnosti
4. Korelace
5. MSE – střední kvadratická chyba
6. SSIM – strukturální podobnost

Kdy u kritéria MSE znamená nejnižší vypočtená hodnota nejlepší výsledek z důvodu, že čím menší je střední kvadratická chyba, tím větší je shoda původního obrázku s jeho zlatým standardem. U ostatních kritérií platí čím vyšší vypočtená hodnota, tím větší je shoda původního obrázku s jeho zlatým standardem.

5.7.1 Prostá podobnost oblastí

Zcela intuitivní kritérium, kdy porovnáme zlatý standard se segmentovanou maskou. Segmentovaná maska se porovná pixel po pixelu a spočítá se, jaké procento segmentovaných pixelů souhlasí z celkového počtu pixelů v obrázku.

Výpočet prosté podobnosti oblasti dvou množin obrazových bodů A a B dostaneme jako:

$$ppo = \frac{A \cap B}{i \cdot j} \quad (31)$$

Kde i, j jsou prvky v množině obrazových bodů, tj. rozlišení obrázku, přičemž musí platit, že $i_A = i_B$ a $j_A = j_B$.

5.7.2 Jaccardovo kritérium podobnosti

Jaccardovo kritérium podobnosti, též označované jako Jaccardův index, je statistický index sloužící k odhadování podobnosti dvou množin jevů. Definován byl již v 19. století, ale lze ho použít i nyní pro hodnocení podobnosti obrazových dat.

Výpočet Jaccardova kritéria dvou množin obrazových bodů A a B stanovíme jako:

$$jaccard(A|B) = |A \cap B| / |A \cup B| \quad (32)$$

5.7.3 Sørensen-Diceho kritérium podobnosti

Obdobné kritérium jako Jaccardův index. Kritérium bylo publikováno ve 40. letech 20. století a původně sloužilo jako statistická veličina pro srovnání podobnosti dvou výběrových množin.

Výpočet Sørensen-Diceho kritéria dvou množin obrazových bodů A a B jako:

$$dice(A|B) = 2 * |A \cap B| / (|A| + |B|) \quad (33)$$

Výpočet lze též vyjádřit pomocí Jaccardova kritéria jako:

$$dice(A, B) = 2 * jaccard(A, B) / (1 + jaccard(A, B)) \quad (34)$$

5.7.4 Korelace

Pro srovnání lze taktéž využít korelační koeficient dvou lineárních matic obrazových bodů A a B jako:

$$\rho(A, b) = \frac{1}{N-1} \sum_{i=1}^N \left(\frac{A_i - \mu_A}{\sigma_A} \right) \left(\frac{B_i - \mu_B}{\sigma_B} \right) \quad (35)$$

Kde N je počet prvků v maticích A a B, μ_A a μ_B jsou aritmetické průměry matic A a B, σ_A a σ_B jsou směrodatné odchylky matic A a B.

5.7.5 MSE – Mean Square Error

MSE – střední kvadratická chyba obrazu je jediné použité kritérium podobnosti, pro které platí: „Čím menší, tím lepší.“ Je to veličina, která vyjadřuje přesnost odhadů s využitím střední hodnoty čtverce rozdílu mezi vstupními maticemi obrazových bodů.

$$MSE = \frac{\sum_{M,N} [I_1(m, n) - I_2(m, n)]^2}{M * N} \quad (36)$$

Kde M a N je počet řádků a sloupců na vstupních obrázcích.

5.7.6 SSIM – Strukturální podobnost

Kritérium SSIM (Structural SIMilarity) popisuje, jak již název napovídá, podobnost struktury dat dvou matic obrazových bodů. Při sestavení metriky obrazových dat se vychází ze tří složek – jas, kontrast a samotné struktury.

Výpočet tohoto kritéria pro dvě matice obrazových bodů A a B organizujeme jako:

$$SSIM(A, B) = [l(x, y)]^\alpha \cdot [c(x, y)]^\beta \cdot [s(x, y)]^\gamma \quad (37)$$

Kde

$$l(A, B) = \frac{2\mu_A\mu_B + C_1}{\mu_A^2 + \mu_B^2 + C_1} \quad (38)$$

$$c(A, B) = \frac{2\sigma_A\sigma_B + C_2}{\sigma_A^2 + \sigma_B^2 + C_2} \quad (39)$$

$$s(x, y) = \frac{\sigma_{AB} + C_3}{\sigma_A\sigma_B + C_3} \quad (40)$$

Při výchozích hodnotách exponentů $\alpha = \beta = \gamma = 1$ se celý výpočet zjednoduší na

$$SSIM(A, B) = \frac{(2\mu_A\mu_B + C_1)(2\sigma_{AB} + C_2)}{(\mu_A^2 + \mu_B^2 + C_1)(\sigma_A^2 + \sigma_B^2 + C_2)} \quad (41)$$

Kde μA a μB jsou aritmetické průměry matic A a B, σA a σB jsou směrodatné odchylky matic A a B, σ_{AB} je kovariance matic A a B.

5.8 Srovnávací skript

Pro srovnání segmentace všech různých nastavení byl vytvořen skript **AlgorithmTest**. Pro správné fungování skriptu je zapotřebí kromě jeho samotného mít k dispozici i dvě složky – RTG prototype a Test patterns. Skript během práce vytvoří další složku Results, kde se ukládají výsledky a výstupy ze skriptu.

1. **AlgorithmTest** – skript provádějící porovnání snímků
2. Složka **RTG prototype** – Obsahuje 10 vybraných RTG snímků
3. Složka **Test patterns** – Obsahuje 10 identických RTG snímků, které byly anotovány a stanoveny jako zlatý standard
4. **Results** – složka, do které se ukládají výsledky, vygenerované tabulky a obrazové srovnání originálu, zlatého standardu, výsledné segmentace a porovnání dvou posledně jmenovaných



Obrázek 20. Znázornění výše uvedené struktury procesu srovnání segmentace: [zdroj vlastní]

5.8.1 AlgorithmTest

Aplikace AlgorithmTest obsahuje všech 58 výše uvedených nastavení algoritmů. Porovnávání probíhá následujícím způsobem:

1. Načtou se všechny testovací snímky, dále se postupuje obrázek po obrázku
2. Provede se kontrola přítomnosti odpovídajícího obrázku zlatého standardu
3. Provede se obrazové předzpracování obrazu
4. Provede se segmentace s daným nastavením
5. Vypočítají se kritéria podobnosti a uloží jejich hodnoty do tabulky s výsledky
6. Provede se obrazová montáž originálu, zlatého standardu, výsledné segmentace a porovnání dvou posledně jmenovaných

7. Obrazová montáž je uložena do složky s výsledky
8. Body 3-7 se provedou se všemi nastaveními, 58 celkem
9. Pro všechna srovnávací kritéria se spočítají kumulované výsledky pro každé jednotlivé nastavení napříč všemi vstupními obrázky
10. Pro všechna srovnávací kritéria se spočítá procentuální chyba každého jednotlivého nastavení vůči nejlepšímu nastavení v rámci onoho srovnávacího kritéria

Celkový výsledek daného nastavení určuje kumulativní přesnost, tj. součet výsledků ze všech deseti testovacích RTG snímků (bod č. 9).


5.8.2 Generování obrázků k jednotlivým algoritmům

Z důvodu značně velkého počtu vygenerovaných obrázků jsou přiloženy ukázky segmentací pouze pro obrázek chodidla. Všechny další vygenerované obrázky naleznete v příloze diplomové práce.


Vygenerované obrázky vždy zobrazují (zleva):

1. Původní obrázek
2. Manuálně vytvořenou binární masku (zlatý standard)
3. Výslednou segmentaci pro dané nastavení
4. Porovnání zlatého standardu a výsledné segmentace


Čtvrtý obrázek je automaticky barevně anotován. Zelená barva značí přítomno na zlatém standardu, ale nepřítomno ve výsledné segmentaci, fialová značí přítomno v segmentaci, ale nepřítomno na zlatém standardu.




Obrázek 21. Otsu prahování s počtem binů 16: [zdroj vlastní]




Obrázek 22. Otsu prahování s počtem binů 96 a aktivními konturami 100 iterací: [zdroj vlastní]




Obrázek 23. Adaptivní prahování (lokální průměr): [zdroj vlastní]




Obrázek 24. Adaptivní prahování (vážený průměr): [zdroj vlastní]



Obrázek 25. Adaptivní prahování (lokální průměr) + aktivní kontury 100 iterací: [zdroj vlastní]



Obrázek 26. Adaptivní prahování (vážený průměr) + aktivní kontury 100 iterací: [zdroj vlastní]



Obrázek 27. Shlukování (k-means) + aktivní kontury 100 iterací [zdroj vlastní]

5.8.3 Report k jednotlivým kritériím

Vybrání výsledného algoritmu probíhalo na základě výsledků srovnávacích kritérií, které reprezentují vytvořené excel soubory, celkem 6 souborů, pro každé srovnávací kritérium je vytvořen jeden samostatný soubor s vypočtenými výsledky. Výsledná podoba obsahu excelu poté vypadá takto:

Algorithm	Chodidlo	Holeň	Hrudník	Koleno	Noha zepředu	Pata	Prsty nohou	Předloktí	Ruka	Sádra	Suma	Ratio
Otsu threshold NoB 16	78,69	95,62	69,31	96,31	92,40	92,29	90,28	92,74	83,12	66,51	857,27	1,96%
Otsu threshold NoB 32	79,30	95,60	70,06	96,33	91,86	90,21	91,05	92,83	83,93	68,62	859,79	1,68%
Otsu threshold NoB 48	78,34	95,64	69,31	96,31	91,86	90,52	90,57	92,93	84,43	70,01	859,91	1,66%
Otsu threshold NoB 64	77,70	95,62	68,82	96,31	91,69	90,52	91,05	92,74	84,67	70,01	859,11	1,75%
Otsu threshold NoB 80	78,34	95,61	69,31	96,24	91,69	90,52	91,05	92,83	84,67	70,01	860,25	1,62%
Otsu threshold NoB 96	78,02	95,62	69,07	96,31	91,69	90,52	90,82	92,74	84,17	72,09	861,05	1,53%
Otsu threshold NoB 112	78,34	95,62	68,82	96,24	91,52	90,52	91,05	92,62	84,17	70,71	859,61	1,70%
Otsu threshold NoB 128	78,02	95,61	68,54	96,31	91,52	90,52	91,05	92,74	84,43	70,71	859,44	1,72%
Otsu threshold NoB 144	78,34	95,62	68,82	96,24	91,52	90,52	91,05	92,62	84,43	70,71	859,87	1,67%
Otsu threshold NoB 160	77,70	95,62	68,82	96,31	91,52	90,52	91,05	92,74	84,67	72,09	861,03	1,53%
Otsu threshold NoB 176	78,02	95,57	68,29	96,24	91,52	90,21	91,22	92,62	84,67	72,09	860,46	1,60%
Otsu threshold NoB 192	78,02	95,62	68,29	96,31	91,52	90,21	91,22	92,62	84,67	72,09	860,58	1,59%
Otsu threshold NoB 208	77,70	95,62	68,29	96,24	91,52	90,52	91,05	92,74	84,67	72,09	860,97	1,54%
Otsu threshold NoB 224	78,02	95,62	68,82	96,31	91,52	90,52	91,05	92,62	84,67	72,09	861,24	1,51%
Otsu threshold NoB 240	77,70	95,57	68,29	96,24	91,52	90,52	91,22	92,74	84,67	72,09	860,56	1,59%
Otsu threshold NoB 256	77,70	95,61	68,54	96,31	91,52	90,52	91,05	92,62	84,67	72,09	860,62	1,58%
Adaptive threshold (Gauss statistic)	79,43	90,97	74,08	94,63	89,11	90,88	77,72	90,46	84,92	70,67	842,87	3,61%
Adaptive threshold (Local Mean)	71,08	82,39	65,69	85,35	82,39	82,88	73,53	82,87	76,65	65,83	768,64	12,10%
Otsu threshold NoB 96 + Active contour (20)	78,02	95,63	68,84	96,34	91,53	90,53	91,02	92,73	84,54	72,09	861,27	1,51%
Otsu threshold NoB 96 + Active contour (40)	78,02	95,62	68,83	96,33	91,54	90,51	91,02	92,73	84,55	72,10	861,26	1,51%
Otsu threshold NoB 96 + Active contour (60)	78,02	95,61	68,84	96,33	91,54	90,52	91,02	92,72	84,55	72,09	861,24	1,51%
Otsu threshold NoB 96 + Active contour (80)	77,99	95,61	68,77	96,33	91,55	90,52	91,02	92,73	84,55	72,08	861,15	1,52%
Otsu threshold NoB 96 + Active contour (100)	77,99	95,63	68,89	96,31	91,54	90,51	91,03	92,73	84,55	72,07	861,24	1,51%
Otsu threshold NoB 96 + Active contour (120)	78,05	95,63	68,83	96,34	91,54	90,52	91,03	92,73	84,56	72,09	861,31	1,50%
Otsu threshold NoB 96 + Active contour (140)	78,05	95,63	68,76	96,34	91,53	90,52	91,03	92,72	84,56	72,09	861,22	1,51%
Otsu threshold NoB 96 + Active contour (160)	78,02	95,63	68,88	96,32	91,53	90,52	91,03	92,74	84,56	72,10	861,33	1,50%
Otsu threshold NoB 96 + Active contour (180)	78,02	95,61	68,83	96,32	91,54	90,51	91,03	92,73	84,57	72,10	861,25	1,51%
Otsu threshold NoB 96 + Active contour (200)	78,02	95,61	68,83	96,31	91,54	90,52	91,03	92,72	84,56	72,09	861,24	1,51%
Adaptive threshold (Local Mean) + Active contour (20)	75,12	93,93	71,86	95,44	87,60	87,69	84,55	90,79	87,00	74,08	848,06	3,02%
Adaptive threshold (Local Mean) + Active contour (40)	75,92	94,81	70,86	95,95	89,34	88,39	88,24	91,58	89,15	76,84	861,09	1,53%
Adaptive threshold (Local Mean) + Active contour (60)	76,29	95,07	69,76	96,15	90,37	88,81	90,29	91,95	89,96	78,06	866,71	0,88%
Adaptive threshold (Local Mean) + Active contour (80)	76,52	95,19	69,15	96,20	90,79	88,95	91,49	92,18	89,97	78,54	868,98	0,62%
Adaptive threshold (Local Mean) + Active contour (100)	76,74	95,25	68,81	96,22	91,03	89,19	92,02	92,28	89,71	78,61	869,86	0,52%
Adaptive threshold (Local Mean) + Active contour (120)	76,86	95,30	68,53	96,25	91,27	89,27	92,42	92,34	89,35	78,53	870,12	0,49%
Adaptive threshold (Local Mean) + Active contour (140)	76,98	95,33	68,46	96,27	91,27	89,36	92,47	92,40	88,95	78,39	869,89	0,52%
Adaptive threshold (Local Mean) + Active contour (160)	77,08	95,36	68,33	96,26	91,41	89,55	92,45	92,50	88,54	78,33	869,83	0,53%
Adaptive threshold (Local Mean) + Active contour (180)	77,15	95,37	68,20	96,26	91,38	89,59	92,45	92,52	88,16	78,14	869,23	0,60%
Adaptive threshold (Local Mean) + Active contour (200)	77,22	95,40	68,26	96,25	91,34	89,60	92,37	92,54	87,85	77,98	868,82	0,64%
Adaptive threshold (Gauss statistic) + Active contour (20)	79,08	94,56	72,55	96,08	91,18	90,64	87,26	92,37	89,14	75,39	868,26	0,71%
Adaptive threshold (Gauss statistic) + Active contour (40)	78,52	94,91	71,72	96,29	91,65	90,52	90,01	92,55	89,53	76,55	872,25	0,25%
Adaptive threshold (Gauss statistic) + Active contour (60)	78,25	95,07	71,09	96,31	91,83	90,43	91,33	92,64	89,60	77,09	873,64	0,09%
Adaptive threshold (Gauss statistic) + Active contour (80)	78,11	95,17	70,72	96,30	91,87	90,46	92,05	92,67	89,47	77,38	874,20	0,03%
Adaptive threshold (Gauss statistic) + Active contour (100)	78,09	95,25	70,40	96,33	91,99	90,45	92,42	92,67	89,29	77,56	874,44	0,00%
Adaptive threshold (Gauss statistic) + Active contour (120)	78,13	95,30	70,21	96,34	92,02	90,42	92,49	92,68	89,08	77,66	874,33	0,01%
Adaptive threshold (Gauss statistic) + Active contour (140)	78,16	95,35	69,98	96,33	91,97	90,42	92,43	92,68	88,88	77,66	873,88	0,06%
Adaptive threshold (Gauss statistic) + Active contour (160)	78,24	95,39	69,77	96,33	91,92	90,42	92,39	92,68	88,69	77,69	873,52	0,10%
Adaptive threshold (Gauss statistic) + Active contour (180)	78,25	95,42	69,73	96,32	91,87	90,41	92,29	92,69	88,46	77,64	873,07	0,16%
Adaptive threshold (Gauss statistic) + Active contour (200)	78,24	95,44	69,65	96,29	91,83	90,40	92,21	92,67	88,24	77,64	872,61	0,21%
K-mean clustering + Active contour (20)	77,70	95,61	68,53	96,34	91,53	90,53	91,05	92,62	84,65	72,09	860,64	1,58%
K-mean clustering + Active contour (40)	77,67	95,61	68,53	96,33	91,52	90,51	91,05	92,62	84,67	72,10	860,59	1,58%
K-mean clustering + Active contour (60)	77,67	95,60	68,52	96,33	91,52	90,52	91,05	92,61	84,66	72,09	860,57	1,59%
K-mean clustering + Active contour (80)	77,67	95,61	68,46	96,33	91,53	90,52	91,05	92,61	84,66	72,08	860,51	1,59%
K-mean clustering + Active contour (100)	77,73	95,61	68,46	96,31	91,52	90,51	91,05	92,62	84,67	72,07	860,54	1,59%
K-mean clustering + Active contour (120)	77,73	95,61	68,53	96,34	91,52	90,52	91,05	92,62	84,66	72,09	860,66	1,58%
K-mean clustering + Active contour (140)	77,73	95,61	68,52	96,34	91,53	90,52	91,05	92,62	84,67	72,09	860,67	1,57%
K-mean clustering + Active contour (160)	77,70	95,62	68,46	96,32	91,52	90,52	91,05	92,61	84,65	72,10	860,54	1,59%
K-mean clustering + Active contour (180)	77,70	95,60	68,57	96,32	91,53	90,51	91,05	92,61	84,65	72,10	860,64	1,58%
K-mean clustering + Active contour (200)	77,70	95,60	68,52	96,31	91,52	90,52	91,05	92,61	84,67	72,09	860,59	1,58%

Obrázek 28. Excel s výsledky prosté podobnosti oblastí (zeleně zvýrazněn nejlepší, červeně nejhorší algoritmus): [zdroj vlastní]

Kdy první sloupec obsahuje vždy název algoritmu, další sloupce obsahují vypočtenou shodu pro konkrétní obrázek. Předposlední sloupec reprezentuje součet hodnot (sumu) z celého řádku, kdy nejvyšší hodnota znamená nejlepší výsledek. V posledním sloupci „ratio“ se stanoví nejvyšší suma jako nula a vůči ní se z ostatních sum spočítá chyba v procentech.

Identicky vypadají všechny ostatní vygenerované soubory s výsledky, vyjma MSE, kde je bráno v potaz, že se jedná „o chybu“, tudíž platí relace „čím menší suma, tím lepší“.

6 Finální algoritmus

Na základě výsledků pro jednotlivá porovnávací kritéria, které můžete vidět v Tabulka 2, byl jako finální algoritmus, který byl implementován do aplikace, vybrán algoritmus adaptivní prahování (vážený průměr) + aktivní kontury (100), který byl ve čtyřech kritériích vyhodnocen jako nejlepší.

Název porovnávacího kritéria	Nejlepší výsledek pro algoritmus
Prostá podobnost oblastí	Adaptivní prahování (vážený průměr) + aktivní kontury (100)
Jaccardovo kritérium podobnosti	Adaptivní prahování (vážený průměr) + aktivní kontury (120)
Sørensen-Diceho kritérium podobnosti	Adaptivní prahování (vážený průměr) + aktivní kontury (120)
Korelace	Adaptivní prahování (vážený průměr) + aktivní kontury (100)
MSE-Střední kvadratická chyba	Adaptivní prahování (vážený průměr) + aktivní kontury (100)
SSIM-Strukturální podobnost	Adaptivní prahování (vážený průměr) + aktivní kontury (100)

Tabulka 2. Nejlepší výsledky pro jednotlivá srovnávací kritéria: [zdroj vlastní]

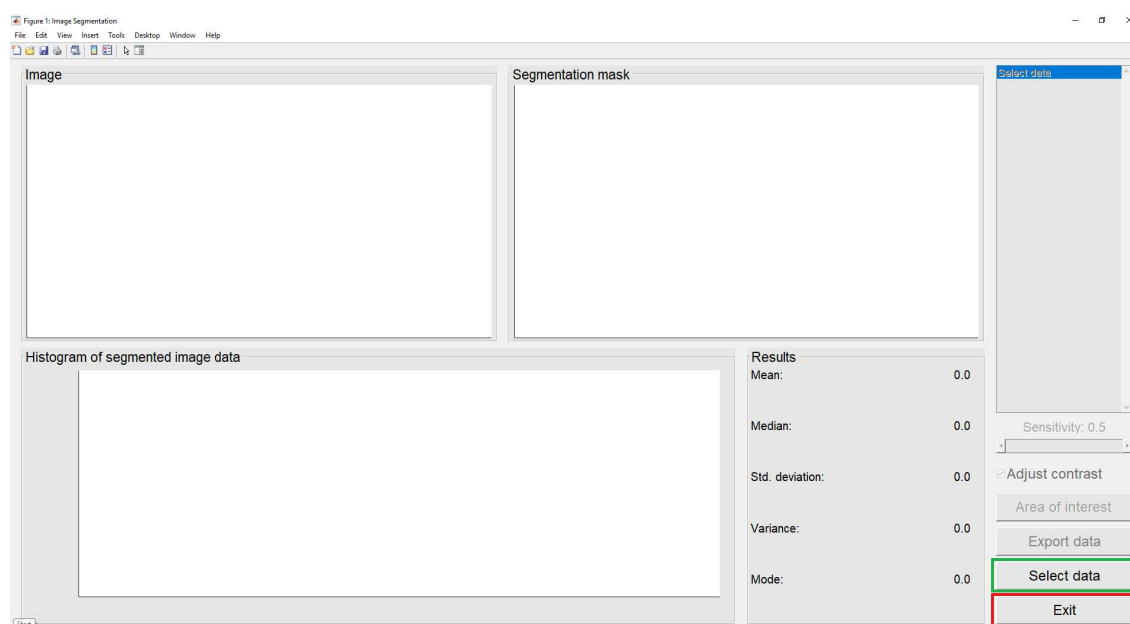
Ve zbylých dvou kritériích byl vyhodnocen identický algoritmus pouze s jiným nastaveným počtem aktivních kontur, kdy rozdíl v rámci těchto dvou kritérií byl shodně vůči vybranému algoritmu zanedbatelných 0.03 %.

7 Grafické uživatelské rozhraní

Součástí práce byl návrh a realizace grafického uživatelského rozhraní. K vytvoření tohoto rozhraní byl použit program MATLAB, kdy ve výsledné aplikaci používám pouze anglický jazyk. Tato kapitola popisuje, jak výsledná aplikace vypadá, jak se chová a jak by se měla používat.

7.1 Vzhled aplikace

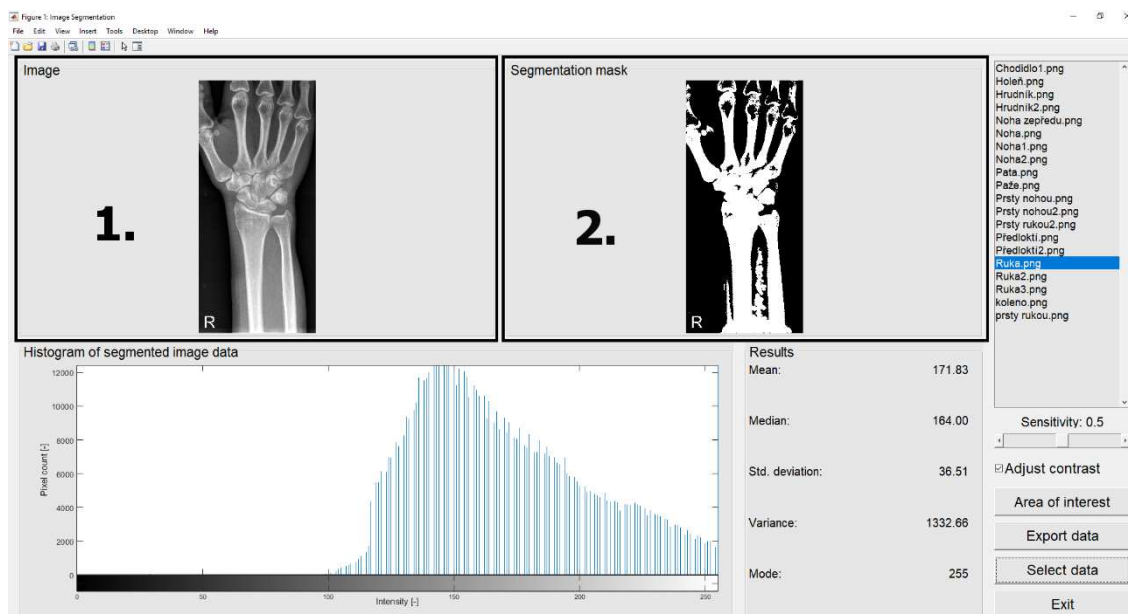
Aplikace po spuštění vypadá takto (Obrázek 29). Aplikace je velice intuitivní a ihned po spuštění nabídne uživateli pouze dvě možnosti výběru – vybrat data (označená zeleně) a možnost zavřít aplikaci (označená červeně).



Obrázek 29. Aplikace po spuštění: [zdroj vlastní]

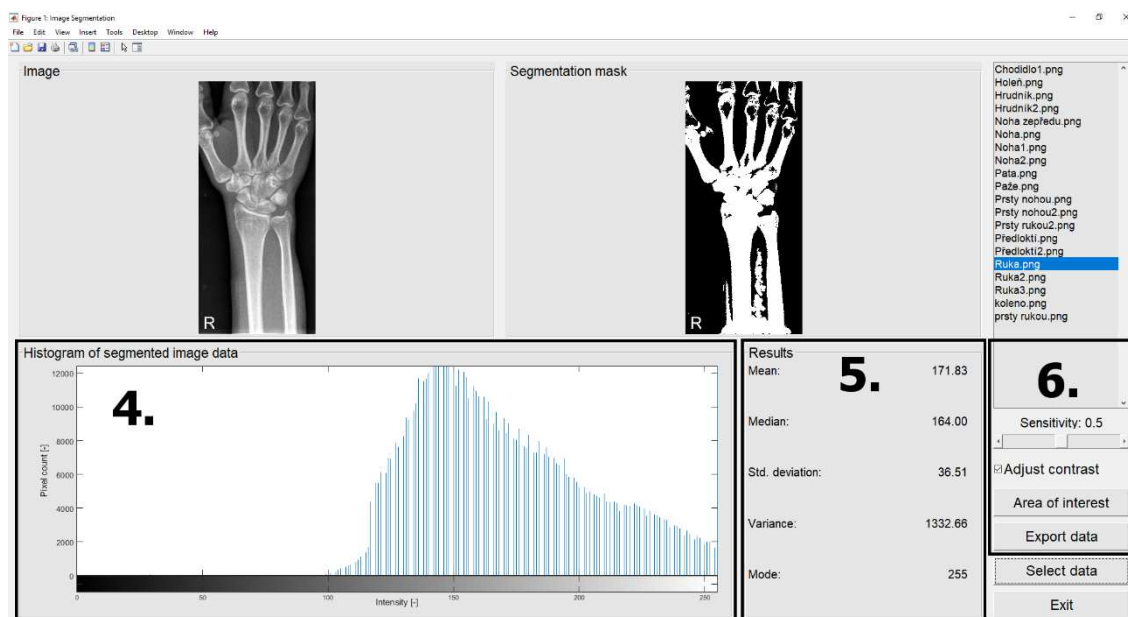
7.2 Prvky v aplikaci

Po úspěšném nahrání dat se ve dvou hlavních oknech (viz Obrázek 30) zobrazí vybraný obrázek (okno číslo 1.) a již segmentovaný obrázek (okno číslo 2.).



Obrázek 30. Zobrazení původního a segmentovaného: [zdroj vlastní]

Na Obrázek 31 vidíme další prvky v aplikaci. Konkrétně vykreslený histogram (okno číslo 4.), vypočítané sledované hodnoty (okno číslo 5.) a možnosti úpravy segmentace a exportu dat (okno číslo 6.).



Obrázek 31. Další prvky v aplikaci: [zdroj vlastní]

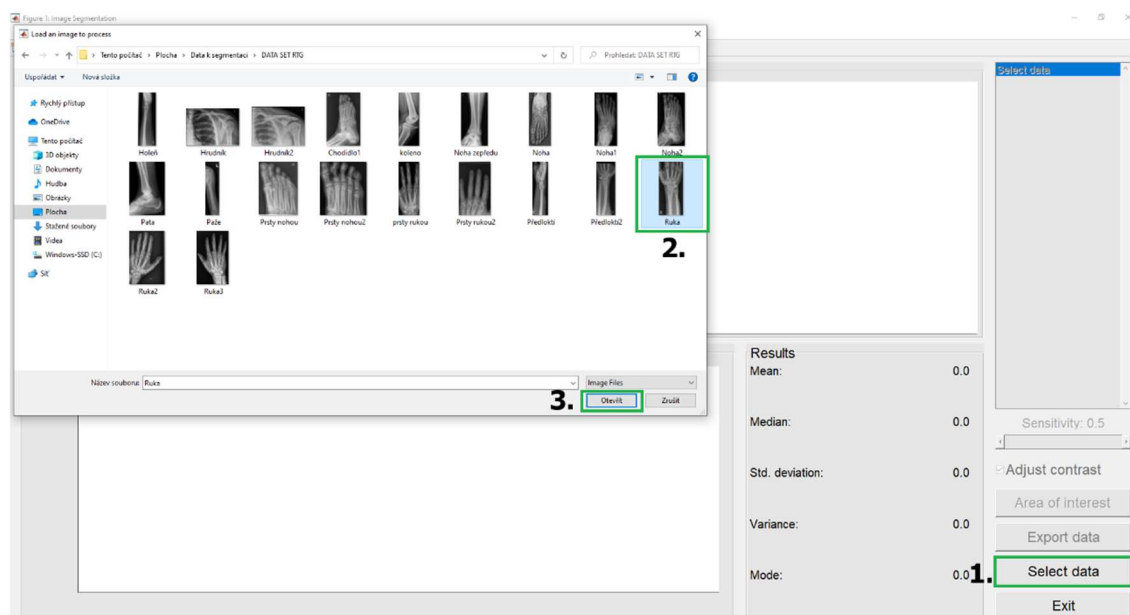
7.3 Postup při výběru dat

Na Obrázek 32 vidíme provedení procesem pro úspěšné vybrání a načtení dat.

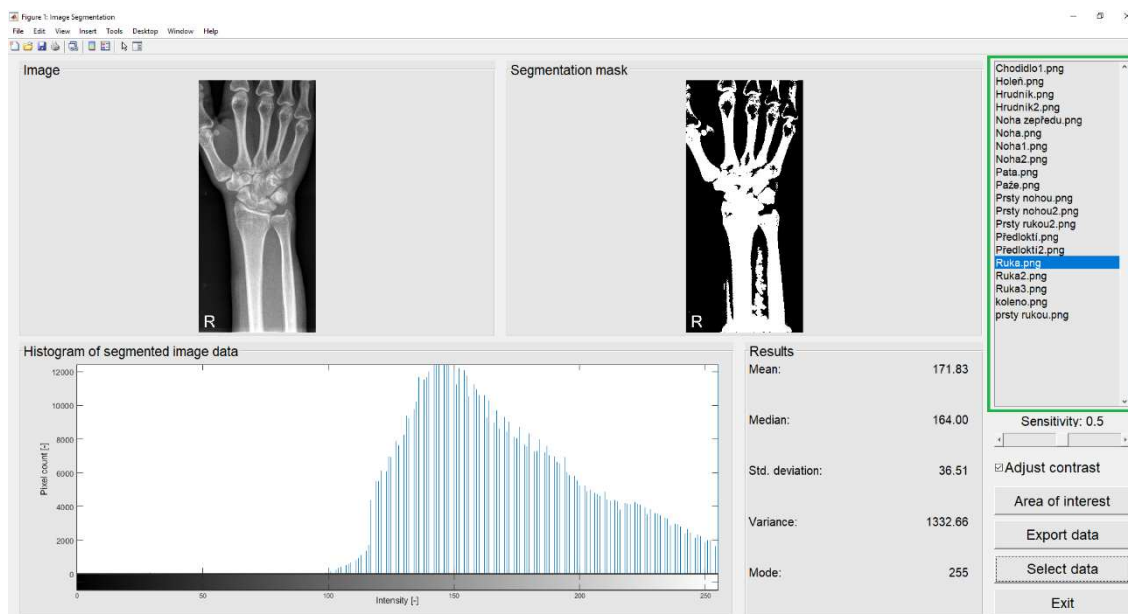
1. Krok 1 spočívá ve stisknutí tlačítka „vybrat data“

2. Krok 2 poté ve vybrání konkrétního snímku
3. Krok 3 potvrzuje volbu vybraného snímku. Všechny kroky jsou rovněž barevně zvýrazněny
4. Po provedení kroku 1-3 dojde k načtení obrázku do aplikace což můžeme vidět na Obrázek 33

Kdy se do okna určeného pro seznam obrázků (označeno zeleně) načte celý obsah složky, ze které byl obrázek vybrán. Obrázek, který byl vybrán uživatelem, se v seznamu obrázků automaticky zvýrazní a mezi jednotlivými obrázky je možné v aplikaci libovolně přepínat. Aplikace zároveň uživateli nedovolí vybrat jiný typ souboru než obrazový nebo DICOM.

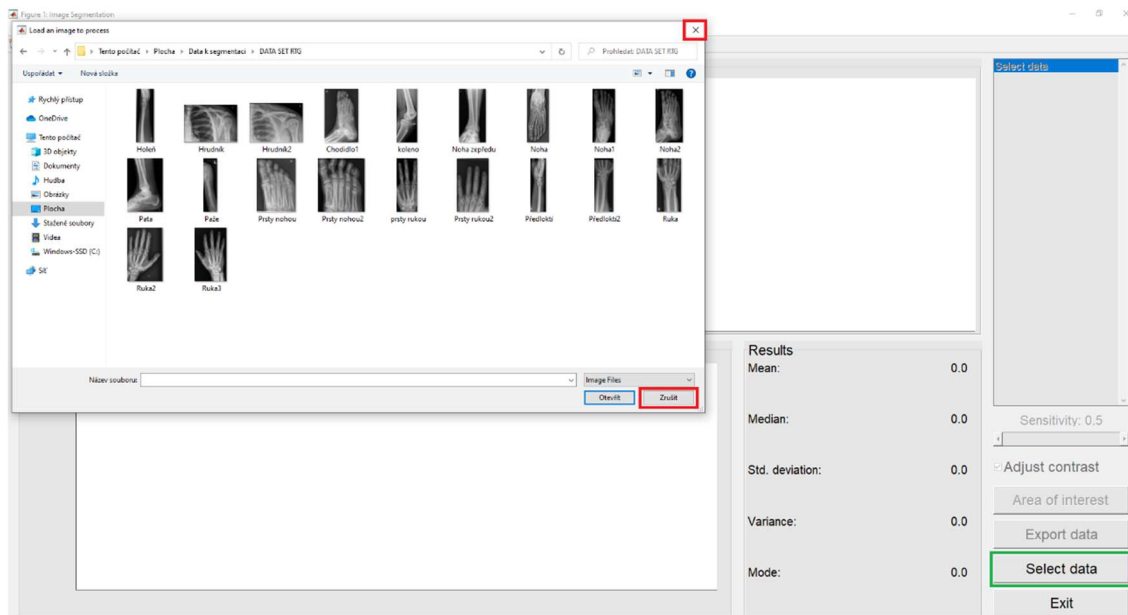


Obrázek 32. Kroky pro vybrání dat: [zdroj vlastní]

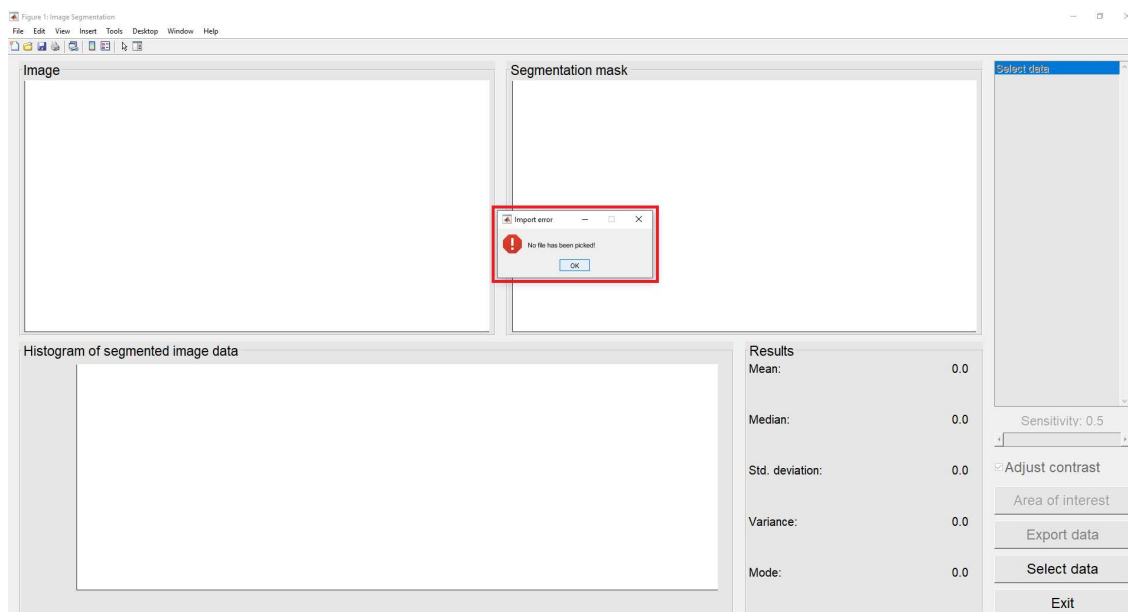


Obrázek 33. Nahraný vybraný obrázek společně s ostatními obrázky: [zdroj vlastní]

V aplikaci také může nastat situace, kterou vidíme na Obrázek 34, kdy se uživatel po stisknutí tlačítka „výběr dat“ (označeno zeleně) rozhodne svou volbu zrušit. To může provést dvěma způsoby (označeno červeně). V takovém případě načtení dat neproběhne a uživatel je o tom informován hláškou „Import error“. Okno s hláškou vidíme na Obrázek 35 (označeno červeně).



Obrázek 34. Zrušení výběru dat: [zdroj vlastní]




Obrázek 35. Import error: [zdroj vlastní]

7.4 Nastavení segmentace

Segmentace se provádí automaticky, a to ihned po načtení vybraného obrázku. Proces běží na pozadí, a to včetně výpočtů statistik.

V aplikaci je možno segmentaci upravovat podle potřeby uživatele. Slouží k tomu jak posuvný slider (který určuje nastavení velikosti sensitivity), tak také zatržítko „adjust image“ (kterým se aktivuje optimalizace histogramu) viz Obrázek 36.



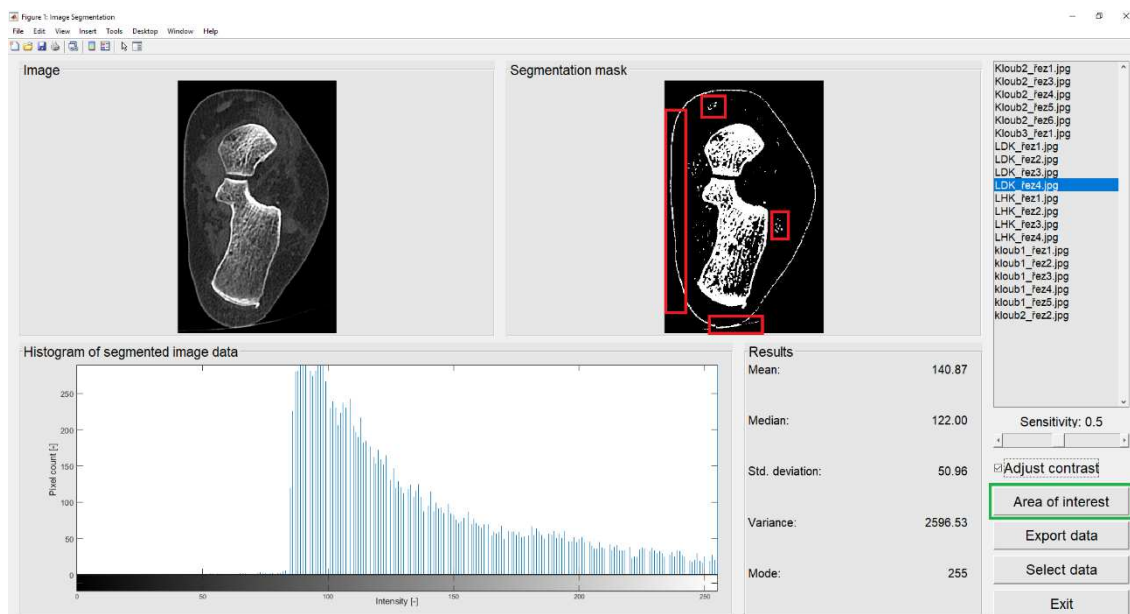
Obrázek 36. Nastavení sensitivity a adjust contrast: [zdroj vlastní]

Princip sensitivity a adjust contrast, je popsán v kapitole Sensitivita a Optimalizace histogramu.

7.5 Načtení vybraných CT dat

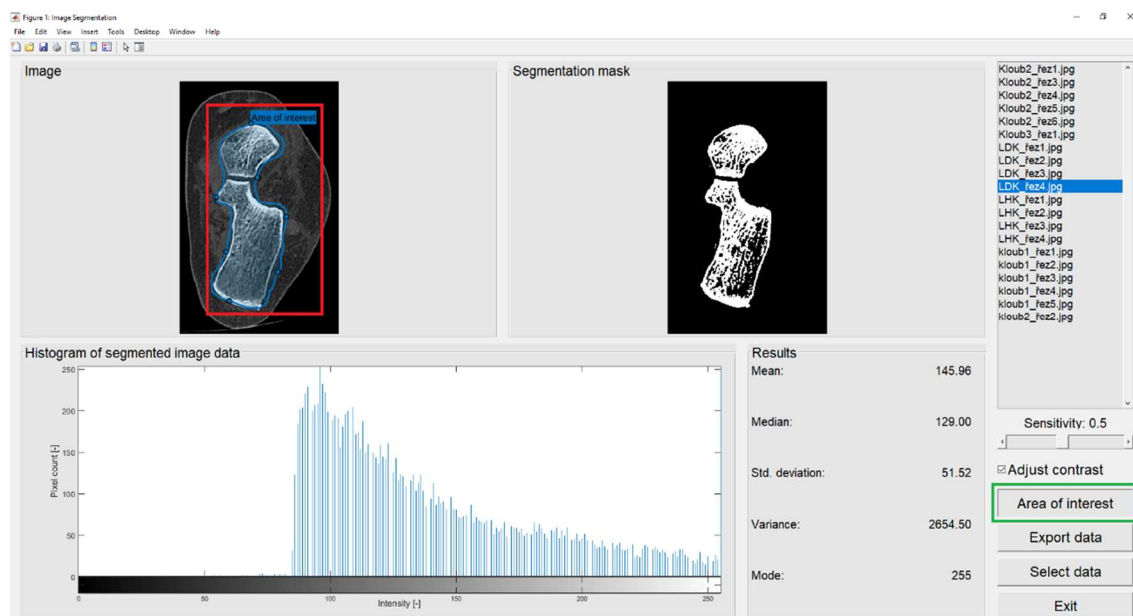
Načtení CT dat probíhá stejným způsobem jako načtení RTG dat. Problém u CT snímků byl ten, že segmentační algoritmus nedetekoval pouze kost samotnou, jak můžeme vidět na Obrázek 37, ale prakticky vždy identifikoval jako kost i okolní tkán, například kůži (označeno

červeně). Tento problém jsem vyřešil přidáním možnosti manuální extrakce oblasti zájmu (označeno zeleně).




Obrázek 37. Segmentace CT snímků se špatnou identifikací kosti: [zdroj vlastní]

Po kliknutí na toto tlačítko (označeno zeleně) se aktivuje vybrání manuální oblasti zájmu, jak můžeme vidět na Obrázek 38. Poté už jen stačí manuálně myší vybrat na původním obrázku oblast zájmu (označeno červeně). Po dokončení vybrání oblasti se automaticky provede nová segmentace, která zahrne pouze vybranou oblast zájmu. Statistiky jsou rovněž počítány pouze z této oblasti.



Obrázek 38. Použití oblasti zájmu: [zdroj vlastní]

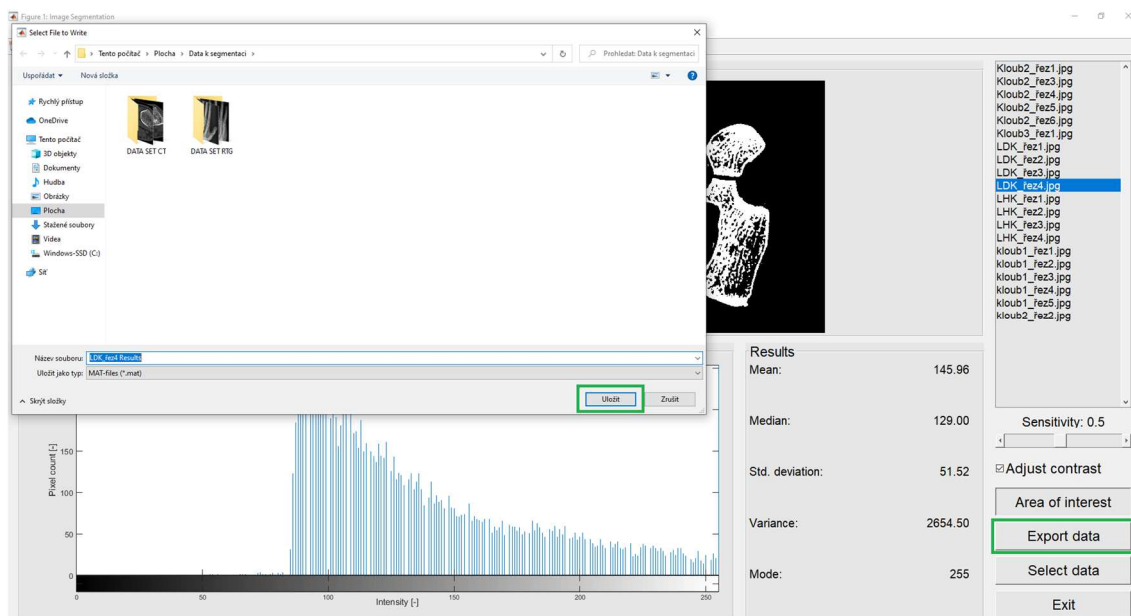


Obrázek 39. Proces použití oblasti zájmu: [zdroj vlastní]

Jak můžeme vidět na Obrázek 39, vlevo máme segmentovaný CT snímek i s okolní tkání. Na obrázku uprostřed je aplikovaná oblast zájmu a na snímku vpravo pak vidíme provedenou segmentaci pouze z oblasti zájmu.

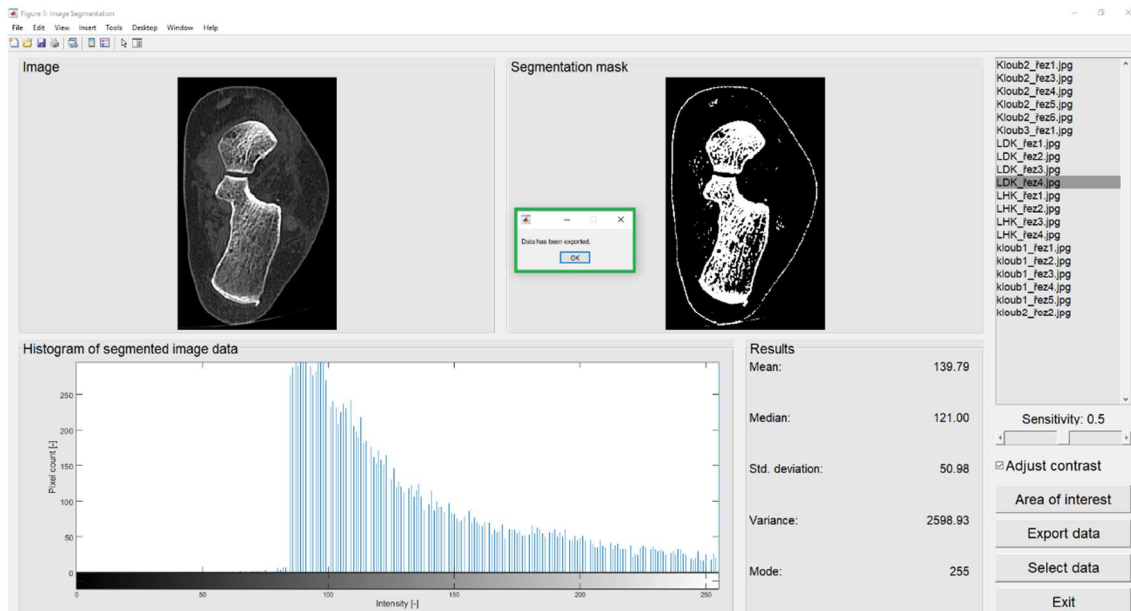
7.6 Export dat

Takto segmentované obrázky je možné společně s vypočítanými statistikami a histogramem exportovat k případnému dalšímu využití a analýze. K tomu slouží v aplikaci tlačítko export data.



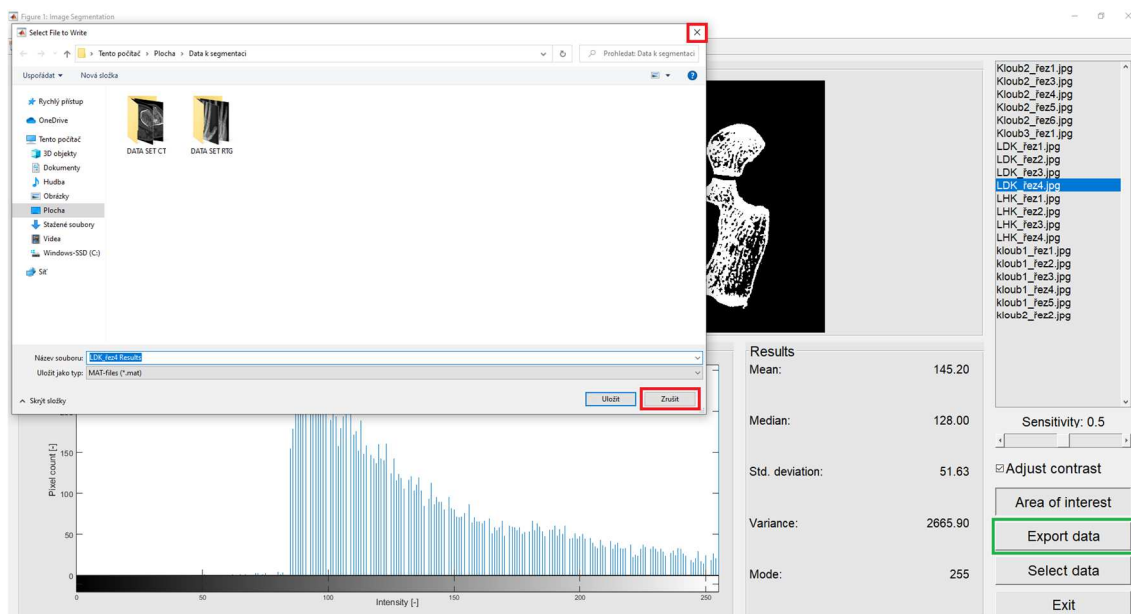
Obrázek 40. Ukázka exportu dat: [zdroj vlastní]

Na Obrázek 40 můžeme vidět, že po stisku tlačítka export data (označeno zeleně) je uživateli nabídnuta možnost data uložit. Data se ukládají pod [název obrázku] result.m. Kdy po kliknutí na tlačítko uložit (označeno rovněž zeleně) se provede export dat a uživateli se oznámí „Data has been exported“ viz Obrázek 41.

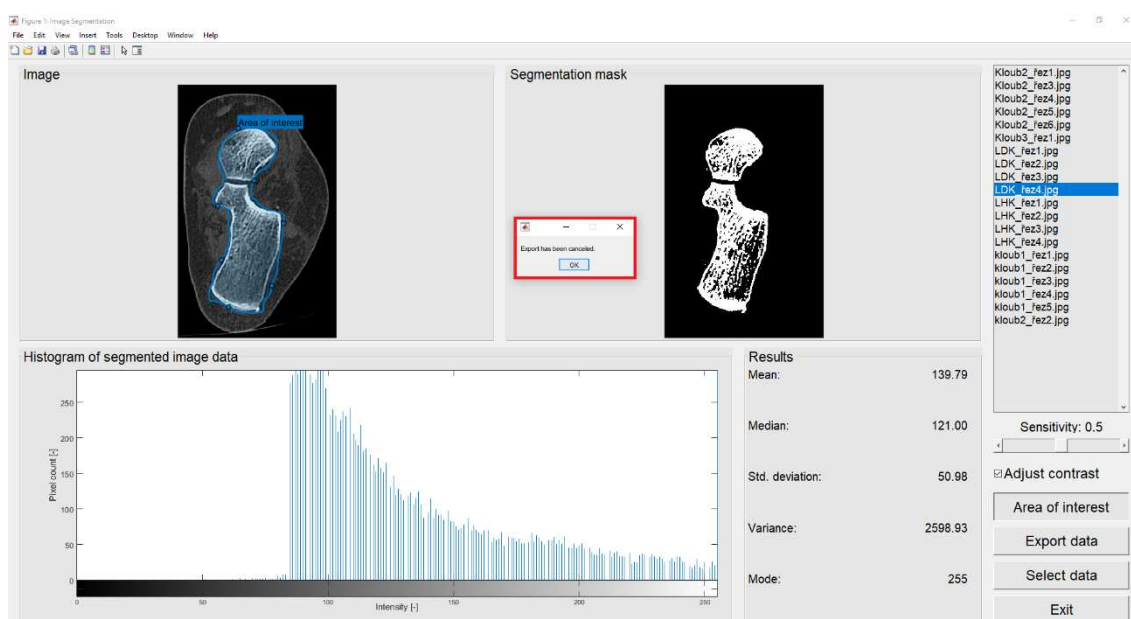


Obrázek 41. Úspěšný export dat: [zdroj vlastní]

Při exportu dat může nastat situace (Obrázek 42), že bude chtít uživatel již aktivovaný export dat (označeno zeleně) zrušit. To je možné provést dvěma způsoby (označeno červeně). V tomto případě se export dat neprovede – jak můžeme vidět na Obrázek 43 – a uživatel je o tom informován hláškou „Export has been canceled“ (označeno červeně).



Obrázek 42. Zrušení již vybraného exportu dat: [zdroj vlastní]



Obrázek 43. Export has been canceled: [zdroj vlastní]

7.7 Formát exportovaných dat

Data se uloží a exportují ve formě matic. Kdy struktura dat uložených v souboru je následující:

1. První sloupec – název uloženého souboru
2. Vstupní obrazová data
3. Binární maska stanovená segmentací a případně oblastí zájmu

4. Výsledný histogram prezentovaný v rozhraní aplikace
5. Do pátého sloupce se poté uloží všechny vypočtené hodnoty

	1	2	3	4	5
1	'LDK_řez4.jp...	398x251 uint8	398x251 logi...	256x1 double	1x1 struct

Obrázek 44. Exportované data: [zdroj vlastní]


Field ▲	Value
Mean	145.9590
Median	129
StandardDeviation	51.5219
Var	2.6545e+03
Mode	255

Obrázek 45. Ukázka obsahu pátého sloupce: [zdroj vlastní]

7.8 Sensitivita

Sensitivita neboli citlivost je koeficient určující, zda se pixel zahrne nebo nezahrne do segmentační masky. V aplikaci je možnost volit sensitivitu v rozmezí 0,1 až 0,9, přičemž čím větší sensitivita, tím více pixelů je zahrnuto a naopak.

Na Obrázek 46 můžeme vidět rozdíly při různém nastavení sensitivity.




Obrázek 46. Ukázka nastavených odlišných sensitivity: [zdroj vlastní]

Kdy základní hodnota sensitivity je v aplikaci nastavena na hodnotu 0,5 na základě toho, že u většiny snímků vykazovalo toto nastavení nejlepší výsledek.


7.9 Optimalizace histogramu

V aplikaci je také možnost zvolit si předzpracování obrazu pomocí zatržítka „Adjust contrast“. Při této volbě se v aplikaci provede optimalizace histogramu s cílem usnadnit segmentaci kostí na vstupním obraze díky lepšímu odlišení od pozadí.

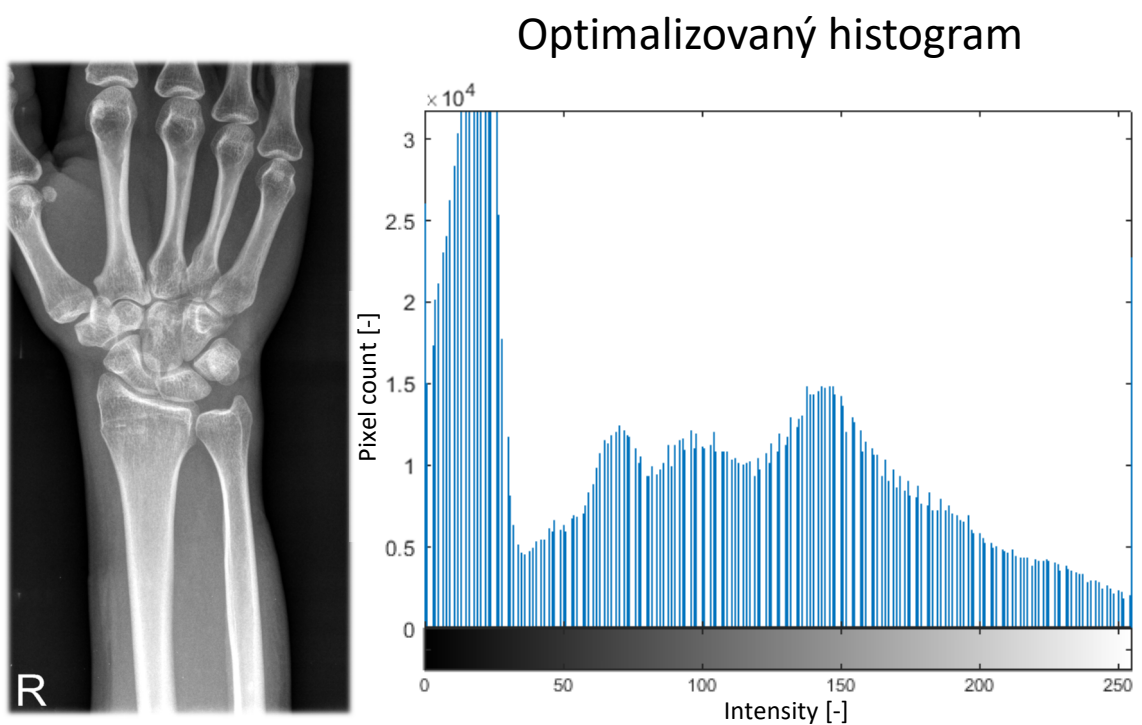
Optimalizace spočívá ve vylepšení distribuce jasu napříč bitovou hloubkou. Při optimalizaci dochází k LUT transformaci 98 % pixelů ve vstupních datech, 1 % nejjasnějších a nejtmavších pixelů se z transformace vynechává. Zbytek je transformován tak, aby šíře bitového kanálu byla využita bezzbytku, viz obrázky níže.



Obrázek 47. Srovnání kumulativní distribuční funkce jasu: [zdroj vlastní]



Obrázek 48. Původní histogram: [zdroj vlastní]



Obrázek 49. Optimalizovaný histogram: [zdroj vlastní]

7.10 Sledované parametry obrazu

V aplikaci se při každé provedené segmentaci zároveň provede výpočet sledovaných parametrů, jejichž seznam uvádím níže. Hodnoty parametrů se stanovují pouze z pixelů, které určí výsledná binární maska.

7.10.1 Průměr (Mean)

Průměr vyjadřuje typickou hodnotu popisující soubor mnoha hodnot. Průměrnou hodnotu značíme \bar{x} .

Vzorec pro její výpočet:

$$\bar{x} = \frac{1}{n} (x_1 + x_2 + \dots + x_n) \quad (42)$$

Kdy průměrnou hodnotu \bar{x} získáme součtem všech hodnot $(x_1 + x_2 + \dots + x_n)$ a vydělením celkovým počtem hodnot n .

7.10.2 Medián (Median)

Pro nalezení mediánu daného souboru stačí hodnoty seřadit podle velikosti a vzít hodnotu, která se nachází uprostřed seznamu. Pokud má soubor sudý počet prvků, tak se z prostředních prvků vypočte průměr.

7.10.3 Rozptyl (Variance)

Rozptyl nám udává, jak moc jsou hodnoty v našem statistickém souboru rozptýleny. Rozptyl vypočteme pomocí tohoto vzorce:

Rozptyl se značí $Var(X)$

$$Var(X) = \frac{1}{N} ((x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_N - \bar{x})^2) \quad (43)$$

Kdy \bar{x} značí průměr, x_N jsou jednotlivé hodnoty a N je celkový počet hodnot.

7.10.4 Směrodatná odchylka (Standard deviation)

Směrodatná odchylka, podobně jako rozptyl, určuje jak moc jsou hodnoty rozptýleny či odchýleny od průměru hodnot. Směrodatná odchylka je rovna odmocnině z rozptylu.

$$\sigma = \sqrt{Var(X)} \quad (44)$$

7.10.5 Modus (Mode)

Modus představuje hodnotu, která se v daném souboru vyskytuje nejčastěji.

7.10.6 Histogram

Histogram graficky znázorňuje distribuci dat pomocí sloupcového grafu. Kdy sloupce mají stejnou šířku a vyjadřují rozsah intervalů (tříd). Výška sloupců znázorňuje četnost veličiny, kterou sledujeme v daném intervalu

8 Komparativní analýza

Tato kapitola je věnována statistice sledovaných parametrů pro RTG a CT data a jejich srovnání. Pro komparativní analýzu bylo vybráno 20 RTG a 20 CT snímků. Následující kapitoly s jednotlivými sledovanými parametry mají vždy stejnou strukturu.

Nejdříve jsou pro přímé srovnání vedle sebe postaveny grafy s výsledky jednotlivých parametrů pro každý z 20 RTG a 20 CT snímků.

Následně jsou pro každý parametr spočítány průměrné hodnoty pro všechny RTG a CT snímky, a ty jsou v grafu porovnány.

Kdy průměrná hodnota pixelů u RTG snímků se od CT snímků lišila pouze minimálně, to znamená, že všechny snímky obsahovaly podobné množství průměrných pixelů.


Průměrná hodnota mediánů už oproti průměrné hodnoty průměru vykazovala větší rozdíl. Konkrétně RTG snímky měly celkově větší prostřední hodnotu pixelů než CT snímky.

Největší rozdíl byl zaznamenán u průměrné hodnoty rozptylu. Pixely CT snímků byly v obrázcích v celkovém součtu rozptýleny o 1x více než hodnoty RTG snímků.


Hodnoty směrodatných odchylek se od sebe lišily téměř o polovinu, takže se dá říct, že si pixely v RTG a CT snímcích jsou navzájem podobné zhruba na 50 %.

Hodnoty modusů byly totožné a u všech snímků měly hodnotu 255, což znamená, že nejčastěji měly ve všech snímcích pixely nejvyšší možnou hodnotu 255.

8.1 Průměrná hodnota průměru




Obrázek 50. Hodnoty průměru v jednotlivých RTG/CT snímcích: [zdroj vlastní]




Graf 1. Průměrná hodnota průměrů CT/RTG snímků: [zdroj vlastní]

8.2 Průměrná hodnota mediánů




Obrázek 51. Hodnoty mediánu v jednotlivých RTG/CT snímcích: [zdroj vlastní]




Graf 2. Srovnání průměrných hodnot mediánu RTG/CT snímků: [zdroj vlastní]

8.3 Průměrná hodnota rozptylů

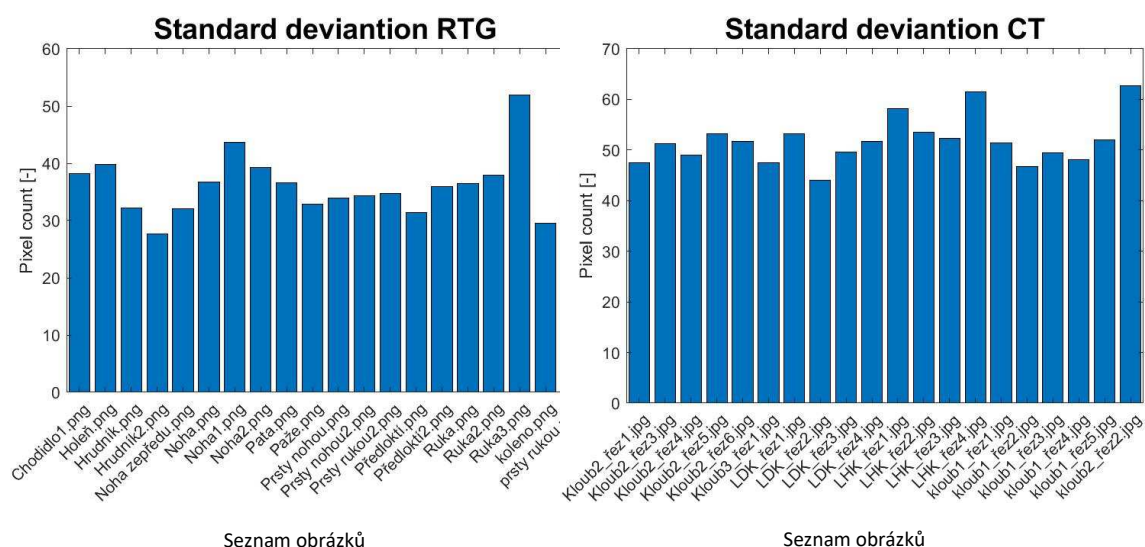


Obrázek 52. Hodnoty rozptylu v jednotlivých RTG/CT snímcích: [zdroj vlastní]




Graf 3. Srovnání průměrných rozptylů RTG/CT snímků: [zdroj vlastní]

8.4 Průměrná hodnota směrodatných odchylek




Obrázek 53. Hodnoty směrodatné odchylky v jednotlivých RTG/CT snímcích: [zdroj vlastní]




Graf 4. Srovnání průměrných směrodatných odchylek RTG/CT snímků: [zdroj vlastní]

8.5 Průměrná hodnota modusů



Obrázek 54. Hodnoty modusů v jednotlivých RTG/CT snímcích: [zdroj vlastní]




Graf 5. Srovnání průměrných modusů RTG/CT snímků: [zdroj vlastní]

8.6 Histogramy

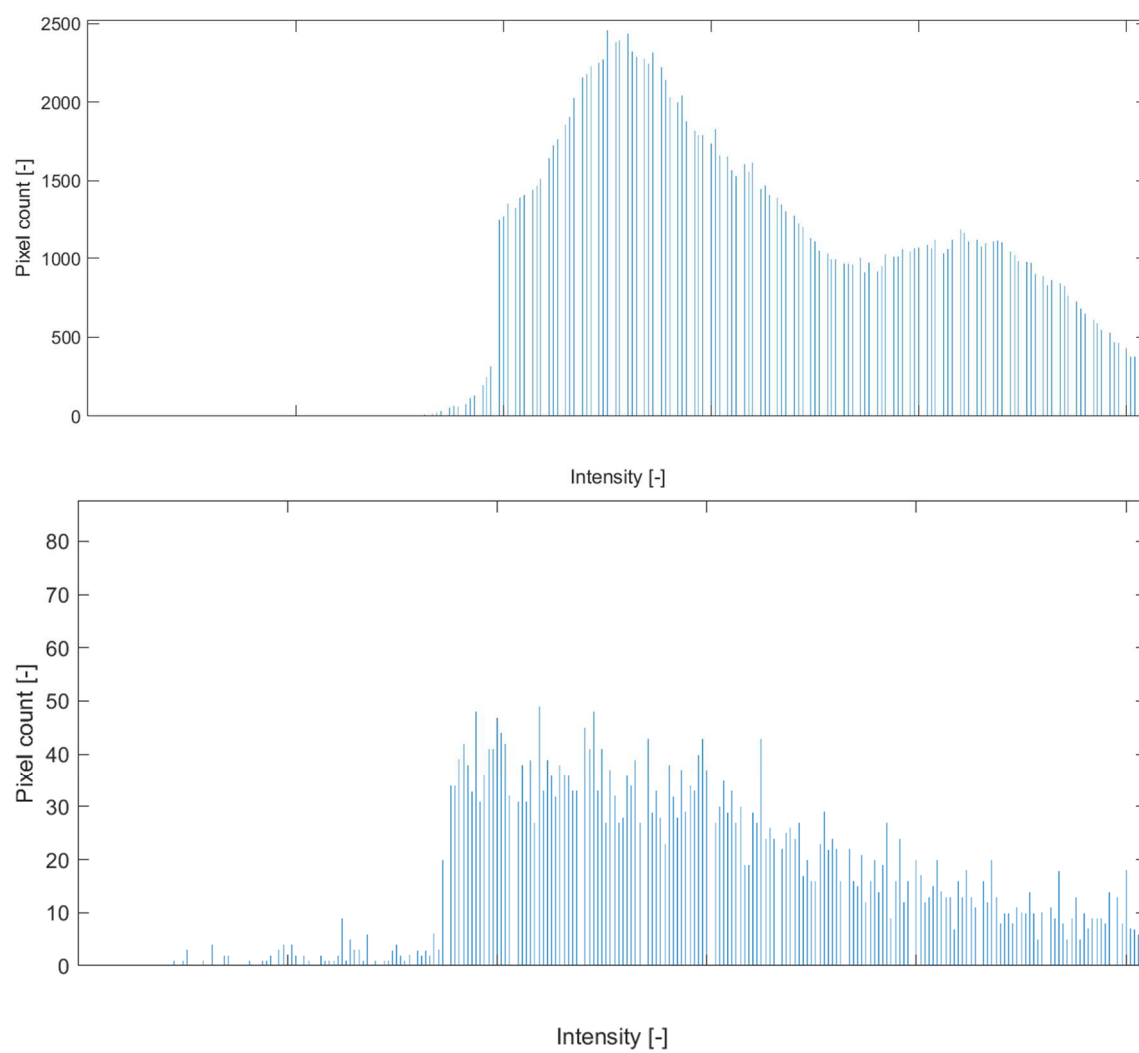
Na závěr je uvedeno srovnání několika histogramů RTG/CT snímků

Kdy obecně lze říct, že histogramy RTG a CT snímků se od sebe výrazně liší. RTG snímky obsahují výrazně větší počet pixelů. Histogramy RTG snímků mají rovněž hladší průběh a jasnější vrcholy.

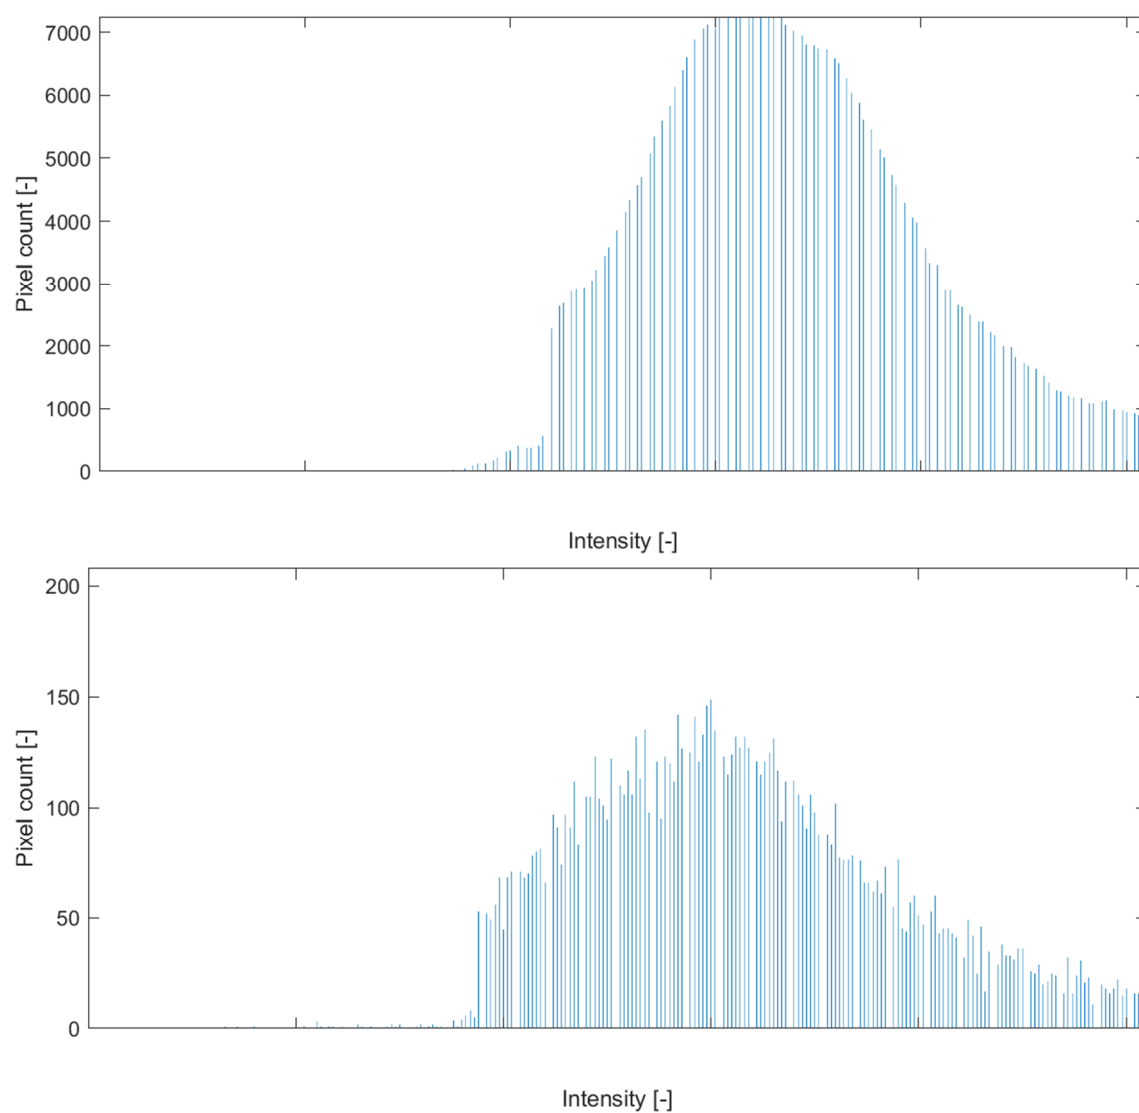
Histogramy ze segmentovaných snímků mohou být využity k jejich pozdější detailnější analýze.



Obrázek 55. Nahoře histogram RTG ruky, dole histogram CT kloubu: [zdroj vlastní]



Obrázek 56. Nahoře histogram RTG nohy, dole histogram CT LHK: [zdroj vlastní]



Obrázek 57. Nahoře histogram RTG prstů rukou, dole histogram CT LDK: [zdroj vlastní]

9 Závěr

Tato práce se zabývala analýzou a modelováním příznaků kostních struktur z RTG a CT obrazových dat. Nejdříve bylo nutné provést vhodný výběr snímků kostí ze souboru RTG a CT dat, se kterým se následně po celou dobu pracovalo. Tyto RTG snímky byly nejprve využity ke statické analýze signifikance příznaků pro modelování hustoty kosti a následnému výběru vhodného algoritmu. Jako nejlepší algoritmus k segmentaci kostí se ukázal algoritmus adaptivního prahování v kombinaci s aktivními konturami. Tento hybridní algoritmus byl následně implementoval do vytvořené aplikace.

Aplikace byla vytvořena v programu MATLAB což umožnilo v segmentovaných datech provádět změny a upravovat segmentaci. Hlavní změny se týkaly možnosti zapnutí/vypnutí předzpracování obrazu a nastavení citlivosti segmentace. Dále pak aplikace přehledně zobrazuje sledované vypočítané statistiky segmentovaných snímků, které je zároveň možné exportovat.

Jak u RTG, tak CT snímků je zároveň velká výhoda možnosti manuálně označit a vybrat pouze oblast, která nás na snímku zajímá. A následný výpočet statistik pouze z těchto vybraných oblastí.

Poslední krok spočíval v provedení segmentace vybraných 20 RTG a 20 CT snímků, kdy byly následně z každého snímku exportovány jeho statistiky. Tyto statistiky poté posloužily ke komparativní analýze mezi RTG a CT snímky, ve které byly tyto statistiky popsány a získané výsledky analyzovány.

Literatura

- [1] Ortopedie-traumatologie.cz. *Revmatoidní artritida* [online]. 2011 [cit. 2020-11-09]. Dostupné z: <http://www.ortopedie-traumatologie.cz/Revmatoidni-artritida%20>
- [2] Medicína pro praxi. *Cushingův syndrom – charakteristika, diagnostika a léčba* [online]. 2009 [cit. 2020-11-09]. Dostupné z: <https://www.medicinapropraxi.cz/pdfs/med/2009/06/02.pdf>
- [3] KALENDER, Willi A. *Computed tomography: fundamentals, system technology, image quality, applications*. 3rd rev. ed. Erlangen: Publicis Publishing, 2011. ISBN 978–3–89578–317–3.
- [4] OPPELT, Arnulf, ed. *Imaging systems for medical diagnostics: fundamentals, technical solutions and applications for systems applying ionizing radiation, nuclear magnetic resonance and ultrasound*. Erlangen: Publicis Corporate Publishing, 2005. ISBN 3–89578–226–2.
- [5] NAVRÁTIL, Leoš a Jozef ROSINA. *Medicínská biofyzika*. Praha: Grada, 2005. ISBN 80-247-1152-4.
- [6] Radiologieplzen.eu. *Fyzikální základy a rtg přístroje* [online]. [cit. 2020-07-29]. Dostupné z: <https://radiologieplzen.eu/ke-stazeni/vyukove-materialy/zcu/>
- [7] VERMA, Bs, a Ik INDRAJIT. *Impact of Computers in Radiography: The Advent of Digital Radiography, Part-2* [online]. 2008 [cit. 2020-07-29]. The Indian Journal of Radiology & Imaging, Medknow Publications, Aug. 2008. Dostupné z: www.ncbi.nlm.nih.gov/pmc/articles/PMC2747436/
- [8] IAEA. *Diagnostic Radiology Physics: a Handbook for Teachers and Students* [online]. 2014 [cit. 2020-07-29]. International Atomic Energy Agency, 2014. Dostupné z: <https://www-pub.iaea.org/MTCD/Publications/PDF/Pub1564webNew-74666420.pdf>
- [9] LLOYD-JONES, Graham. *Basics of X-Ray Physics Tissue Densities* [online]. 2016 [cit. 2020-07-29]. Radiology Masterclass, 2016. Dostupné z: www.radiologymasterclass.co.uk/tutorials/physics/x-ray_physics_densities
- [10] MARSH, Phillip. *X-Ray Hand – Labelling Questions* [online]. 2020 [cit. 2020-07-29] Radiopaedia.org. Dostupné z: radiopaedia.org/cases/x-ray-hand-labelling-questions?lang=gb
- [11] Urmc.rochester.edu. *Computed Tomography (CT) Scan of the Bones* [online]. 2020 [cit.

- 2020-07-29]. Health Encyclopedia, University of Rochester Medical Center. Dostupné z: www.urmc.rochester.edu/encyclopedia/content.aspx?contenttypeid=92&contentid=P07649
- [12] FENG, Ding a Leow Wee KHENG. *Segmentation of Bone Structures in X-ray Images* [online]. 2006 [cit. 2020-11-09]. National University of Singapore, School of Computing. Dostupné z: <https://www.comp.nus.edu.sg/~leowwk/thesis/dingfeng-proposal.pdf>
- [13] FELZENSZWALB, Pedro a Daniel HUTTENLOCHER. *Efficient Graph-Based Image Segmentation* [online]. [cit. 2020-11-09]. Dostupné z: <http://people.cs.uchicago.edu/~pff/papers/seg-ijcv.pdf>
- [14] ŠPANĚL, Michal a Vítězslav BERAN. *Obrazové segmentační techniky* [online]. 2006 [cit. 2020-11-09]. Vysoké učení technické v Brně, Fakulta informačních technologií. Dostupné z: http://www.fit.vutbr.cz/~spanel/segmentace/#_Toc125769331
- [15] FOGELMAN, Ignac a Glen M. BLAKE. *Different Approaches to Bone Densitometry* [online]. 2000 [cit. 2020-07-29]. Journal of Nuclear Medicine, 2000, vol. 41 no. 12. Dostupné z: jnm.snmjournals.org/content/41/12/2015.full
- [16] GONZALEZ, Rafael C. a Richard E. WOODS. *Digital image processing*. 2nd ed. Upper Saddle River: Prentice Hall, c2002. ISBN 0–201–18075–8.
- [17] ŽÁRA, Jiří, Bedřich BENEŠ, Jiří SOCHOR a Petr FELKEL. *Moderní počítačová grafika*. 2. vyd. Praha: Computer Press, 2005. 609 s. ISBN 80-251-0454-0.
- [18] DICOM. *Key concepts* [online]. [cit. 2020-08-15] Digital Imaging and Communications in Medicine. Dostupné z: <https://www.dicomstandard.org/concepts>
- [19] HLAVÁČ, Václav a Milan ŠONKA. *Počítačové vidění*. Praha: Grada, 1992. ISBN 80-85424-67-3.
- [20] SHUBHANGI, D. C. et al. *Edge Detection of Femur Bones in X-Ray Images A Comparative Study of Edge Detectors*. International Journal of Computer Applications, vol. 42, no. 2, 2012, pp. 13–16., doi:10.5120/5663-7696.
- [21] SONKA, Milan, Vaclav HLAVAC a Roger BOYLE. *Image processing, analysis, and machine vision*. New York: Chapman & Hall Computing, 1993. Chapman and Hall computing series. ISBN 978-0-412-45570-4.
- [22] COSTA, Luciano da Fontoura a Roberto Marcondes CESAR. *Shape analysis and classification: theory and practice*. Boca Raton: CRC Press, c2001. Image processing series.

ISBN 0–8493–3493–4.

- [23] SOJKA, Eduard, Jan GAURA a Michal KRUMNIKL. *Matematické základy digitálního zpracování obrazu* [online]. 2011 [cit. 2020-11-09]. Vysoká škola báňská v Ostravě. Dostupné z: http://mi21.vsb.cz/sites/mi21.vsb.cz/files/unit/digitalni_zpracovani_obrazu.pdf
- [24] SU, Liyilei a kol. *Delineation of Carpal Bones From Hand X-Ray Images Through Prior Model, and Integration of Region-Based and Boundary-Based Segmentations*. *IEEE Access*, vol. 6, pp. 19993-20008, 2018, doi: 10.1109/ACCESS.2018.2815031.
- [25] BEUCHER, Serge a F. MEYER *Segmentation: The Watershed Transformation*. *Mathematical Morphology in Image Processing*. 1993. Optical Engineering. 34. 433-481. Dostupné z: https://www.researchgate.net/publication/233950923_Segmentation_The_Watershed_Transformation_Mathematical_Morphology_in_Image_Processing
- [26] NG, H.p., et al. *Medical Image Segmentation Using K-Means Clustering and Improved Watershed Algorithm*. *IEEE Southwest Symposium on Image Analysis and Interpretation*, Feb. 2001, doi:10.1109/ssiai.2006.1633722.
- [27] CHAUHAN, Nagesh Singh. *Introduction to Image Segmentation with K-Means clustering* [online]. 29. 7. 2019 [cit. 2020-08-15]. Towards Data Science. Dostupné z: <https://towardsdatascience.com/introduction-to-image-segmentation-with-k-means-clustering-83fd0a9e2fc3>
- [28] OTSU, N., "A Threshold Selection Method from Gray-Level Histograms," *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. 9, No. 1, 1979, pp. 62-66. BIRDAL, T., *Famous Otsu Thresholding in C#*, The Code Project, [online]
- [29] Bradley, D., G. Roth, "Adaptive Thresholding Using the Integral Image," *Journal of Graphics Tools*. Vol. 12, No. 2, 2007, pp.13-21.

Seznam příloh

- I. AlgorithmTest.m | Script pro výběr vhodného algoritmu
- II. Složka RTG prototype | Obsahující 10 RTG snímků pro výběr algoritmu
- III. Složka Test patterns | Obsahující 10 manuálně anotovaných RTG snímků
- IV. Složka Result | Obsahující grafické výsledky ve formátu PNG. a zároveň vypočtené výsledky z výběru algoritmu ve formátu xls.
- V. ImageSegmentation.m | Samotná aplikace, ve které se provádí segmentace
- VI. Složka data set RTG | Obsahující 20 RTG snímků, které byly segmentovány
- VII. Složka data set CT | Obsahující 20 CT snímků, které byly segmentovány
- VIII. Složka Result CT | Obsahující vypočítané statistiky z 20 CT snímků ve formátech JPG, xls a Matlab code.m
- IX. Složka Result RTG | Obsahující vypočítané statistiky z 20 RTG snímků ve formátech JPG, xls a Matlab code.m